

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Filtrace šumu typu speckle v ultrazvukových obrazech

Speckle noise filtration in ultrasound images

Zadání diplomové práce

Student:

Bc. Dominik Vilímek

Studijní program:

N2649 Elektrotechnika

Studijní obor:

3901T009 Biomedicínské inženýrství

Téma:

Filtrace šumu typu speckle v ultrazvukových obrazech
Speckle Noise Filtration in Ultrasound Images

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Nastudování základních konvenčních metod pro filtraci digitálního obrazu.
2. Nastudování objektivizačních parametrů pro hodnocení kvality obrazové filtrace.
3. Rešerše metod pro eliminaci šumu z ultrazvukových obrazů.
4. Design šumových generátorů pro ultrazvuková obrazová data.
5. Tvorba testovací datové báze ultrazvukových klinických obrazů.
6. Návrh vybraných algoritmů pro eliminaci speckle šumu pro ultrazvuková obrazová data.
7. Testování metod na reálných klinických ultrazvukových datech pro variantní typy obrazového šumu.
8. Objektivní evaluace každé navržené metody na základě vybraných parametrů.
9. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] AZHARI, Haim. *Basics of biomedical ultrasound for engineers*. Hoboken, N.J.: IEEE, 2010. ISBN 978-0-470-46547-9.
- [2] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL: Taylor & Francis, 2006. ISBN 0-8247-5849-8.
- [3] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. *Handbook of biomedical image analysis*. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48607-5.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 30.04.2019




doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry


prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

„Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární
prameny a publikace, ze kterých jsem čerpal.“

V Ostravě 30. 4. 2019


.....

Rád bych na tomto místě poděkoval panu Ing. Janu Kubíčkovi, Ph.D., za všechny rady, poskytnuté materiály a čas strávený nad problematikou této diplomové práce. Dále bych rád poděkoval Ing. René Jarošovi, své přítelkyni, rodině a blízkým za veškerou podporu během studia.

Abstrakt

Tato diplomová práce se zabývá potlačením strukturního šumu typu speckle v ultrazvukových snímcích prostřednictvím vlnkové transformace. Speckle šum je v ultrazvukovém obraze charakteristický svým zrnitým charakterem, se kterým je možno zacházet jako se šumem a hledat možnosti jak ho potlačit, nebo ho lze považovat ze signál charakterizující strukturu, do které patří. Cílem této diplomové práce bylo testování vlivu dynamiky šumu na efektivitu kooperativních vlnek na vytvořených reálných klinických ultrazvukových datech. Nejprve se práce věnuje rozsáhlé rešerši zabývající se stručným popisem ultrasonografie, variantních typů šumu a jejich možné filtraci. Praktická část práce je zaměřena na vytvoření klinické testovací databáze a dále je vytvořen návrh popisující algoritmus zvolené metody. Primárně se tato práce zaměřuje na testování efektivitu filtrace kooperativních vlnek pro variantní typy šumu a to především pro šum typu speckle. Podstatou práce je tvorba testovacího prostředí pro dynamickou simulaci vlivu intenzity deterministických šumů. Funkčnost navržené metody filtrace je otestována na třech odlišných vytvořených databázích. Hodnocení kvality filtrace je provedeno na základě zvolených objektivních parametrů.

Klíčová slova: Ultrasonografie, ultrazvukové zobrazovací módy, speckle, konvenční metody filtrace, pokročilé metody filtrace, vlnková transformace, diskrétní vlnková transformace, hodnocení kvality obrazové filtrace

Abstract

This diploma thesis deals with suppression of structural speckle noise in ultrasound images by wavelet transformation. Speckle noise in ultrasound images is characterized by a grainy character which can be treated as noise and ways to suppress it can be found, or it may be considered as a signal characterizing the structure to which it belongs. The aim of this thesis was to test the effect of noise dynamics on the efficiency of cooperative waves on the created real clinical ultrasound data. At first, the thesis deals with a comprehensive research dealing with a brief description of ultrasonography, variant types of noise and their possible filtration. The practical part of the thesis is focused on the creation of a clinical test database and furthermore, a design describing an algorithm of the chosen method is created. Primarily, this work focuses on testing the efficiency of cooperative wavelets filtering for variant types of noise, especially for speckle noise. The essence of the work is to create a test environment for dynamic simulation of the influence of the intensity of deterministic noise. The functionality of the proposed filtering method is tested on three different created databases. Filtering quality assessment is conducted based on the selected objective parameters.

Key Words: Ultrasound, ultrasound imaging modes, speckle, conventional filtration methods, advanced filtration methods, wavelet transform, discrete wavelet transform, image quality assessment

Obsah

Seznam použitých zkratk a symbolů	8
Seznam obrázků	11
Seznam tabulek	13
Úvod	14
1 Ultrasonografie	15
1.1 Módy ultrazvukového zobrazování	16
1.2 Artefakty v ultrasonografii	20
2 Obrazová filtrace a její hodnocení	22
2.1 Charakteristika obrazu	22
2.2 2D cyklická konvoluce	24
2.3 Typy filtrace	25
2.4 Subjektivní a objektivní hodnocení obrazové kvality	28
3 Metody pro eliminaci šumu z ultrazvukových obrazů	33
3.1 Jednotlivé typy šumu	33
3.2 Pokročilé metody filtrace	35
4 Implementace algoritmu eliminace šumu z ultrazvukových dat	42
4.1 Technické parametry ultrazvukového přístroje	43
4.2 Tvorba testovací databáze ultrazvukových klinických obrazů	44
4.3 Aplikace šumových generátorů pro ultrazvukové obrazy	45
4.4 Vlnková transformace	50
4.5 Vlastní filtrace	54
5 Hodnocení filtrace variantních typu šumu na reálných klinických datech	56
5.1 Výsledky filtrace pro Gaussův šum	57
5.2 Výsledky filtrace pro Salt and Pepper šum	64
5.3 Výsledky filtrace pro Speckle šum	71
6 Objektivní zhodnocení filtrace Speckle šumu	81
6.1 Výsledky databáze břicho	81
6.2 Výsledky databáze karotidy	83
6.3 Výsledky databáze krk	85
6.4 Výpočetní náročnost algoritmu	87

6.5 Subjektivní posouzení kvality obrazové filtrace	88
7 Diskuze	90
Závěr	91
Literatura	92
Přílohy	97
A Seznam příloh na přiloženém DVD	98

Seznam použitých zkratek a symbolů

α	– Úhel alfa, adaptivní koeficient
$a_{i,j}$	– Aditivní šum
c	– Rychlost vlnění
\cos	– Cosinus
CW	– Dopplerovský systém s kontinuální vlnou
CWT	– Kontinuální vlnková transformace
C_B	– Variační koeficient šumu
C_I	– Variační koeficient zašuměného obrazu
c_1	– Hodnota konstanty použité pro výpočet metriky SSIM
c_2	– Hodnota konstanty použité pro výpočet metriky SSIM
4D	– Zorazení v reálném čase
D	– Dynamický rozsah intenzity pixelů
d	– parametr hustoty šumu
dB	– Decibel
db	– Příjmení vlnky Daubechies
DR	– Dynamický rozsah
2D	– Dvoudimenzionální
1D	– jednodimenzionální
DWT	– Diskrétní vlnková transformace
$D_{j,k}$	– Vlnkové koeficienty
f	– Frekvence
f	– Hodnota přiměřeného jasů v bodech x a y
f	– Digitální hodnota
$f_{i,j}$	– Funkce intenzity pixelů
$f_{i,j}$	– Pixel s nejvyšší intenzitou
$f_{i,j}$	– Zkušební obraz
F_n	– Výstupní sekvence
$F(u, v)$	– Fourierova transformace f(x, y)
$\hat{F}(x, y)$	– Obnovený obraz
$f(x, y)$	– Konvoluce obrazu
δf	– Frekvence, která se zvyšuje s rychlostí pohybujícího se objektu
$\log f_{i,j}$	– Pixel neobsahující šum a šumový komponent
GAE	– Geometric average error
λ	– Vlnová délka
λ	– Prahová hodnota
$g_{i,j}$	– Odhad skutečné intenzity

$g_{i,j}$	– Pixel, který neobsahuje šum
$g_{i,j}$	– Originální obraz
$G_{(n)}$	– Vstupní sekvence
$G(u, v)$	– Fourierova transformace $g(x, y)$
$g(x, y)$	– Výsledný obraz
HH	– Diagonální detaily
HL	– Vertikální detaily
$H(u, v)$	– Fourierova transformace $h(x, y)$
$h(x, y)$	– Operátor
Hz	– Hertz
H_{max}	– Nejsvětlejší pixel
H_{min}	– Nejtmavší pixel
$H_{(x,y)}$	– Konvoluční jádro
I	– Míra odlišnosti hodnot
I	– Vstupní obraz
J	– Výstupní obraz
j	– Digitální hodnota
K	– Kontrast
k	– Normalizační konstanta
L	– Počet pixelů v části zpracovaného obrazu
LH	– Horizontální detaily
LL	– Aproximace
M	– Počet pozorovatelů
m	– Střední hodnota funkce
MED	– Mediánová operace
MHz	– Megahertz
MOS	– Mean Opinion Score (střední hodnota názoru)
MSE	– Mean squared error (střední kvadratická chyba)
n_i	– Pixel neobsahující šum a šumový komponent
(n, n)	– Aktuální pixel
PMAD	– Perona a Malik anisotropní difúzní filtr
P_s	– Počet vlnkových koeficientů
PSNR	– Peak signal to noise ratio (špičkový poměr signálu k šumu)
PW	– Pulzní doplerovský systém
ψ	– Mateřská vlnka
Q-index	– Quality index (univerzální index kvality)
RGB	– Barevný model (červená - zelená - modrá)
RMSE	– Root mean squared error (střední kvadratická odchylka)
s	– Dilatační škálovací parametr

$S(i, k)$	– Vyhodnocací skóre obrazu k , pozorovatelem i
σ	– Směrodatná odchylka
σ^2	– Rozptyl
SNR	– Signal to noise ratio (poměr signálu k šumu)
SRAD	– Speckle redukující anisotropní difúze
SSIM	– Structural similarity index (strukturální index podobnosti)
sym	– Příjmení vlnky Symlets
t	– Univerzální práh, Hodnota Steinova nezkresleného odhadu rizika
τ	– Translační škálovací parametr
3D	– Trojdimenzionální
$u_{i,j}$	– Multiplikativní šum
USG	– Ultrasonografie
UZ	– Ultrazvuk
UZV	– Ultrazvuk
μ	– Střední hodnota
v	– Rychlost
$V_{x,y}$	– Koeficient vlnky HH
$Wf_{(\tau,s)}$	– Vlnkový koeficient
$W(x, y)$	– Adaptivní filtrační koeficient
X_N	– Hodnota N vstupního prvku
x_i	– Ultrazvukový obraz po logaritmické kompresi
z	– Škála šedi

Seznam obrázků

1	Interakce s prostředím	15
2	Dopplerův efekt	16
3	Příklady echogenních struktur	17
4	Zobrazení spektrálního Dopplera	18
5	Reverberace	20
6	Zrcadlový artefakt	21
7	Ekvalizace histogramu	24
8	Klasifikace filtrace v prostorové doméně	25
9	Grafické znázornění operace mediánového filtru	27
10	Funkce hustoty pravděpodobnosti Gaussova šumu	33
11	Poškození centrálního pixelu šumem Salt and Pepper	34
12	Klasifikace filtrů ve vlnkové doméně	39
13	Návrh řešení praktické části	42
14	Ultrazvukový přístroj GE LOGIQ P6 PRO	43
15	Ukázka vytvořené klinické databáze.	44
16	Vývojový diagram znázorňující aplikaci variantních typů šumu	45
17	Ukázka zašuměných klinických snímků z databáze břicho Gaussovým šumem. . .	46
18	Ukázka zašuměných klinických snímků z databáze karotidy Gaussovým šumem. .	46
19	Ukázka zašuměných klinických snímků z databáze krk Gaussovým šumem. . . .	47
20	Ukázka zašuměných klinických snímků z databáze břicho šumem typu Salt and Pepper.	47
21	Ukázka zašuměných klinických snímků z databáze karotidy šumem typu Salt and Pepper.	47
22	Ukázka zašuměných klinických snímků z databáze krk šumem typu Salt and Pepper.	48
23	Ukázka zašuměných klinických snímků z databáze břicho šumem typu Speckle. .	48
24	Ukázka zašuměných klinických snímků z databáze karotidy šumem typu Speckle.	49
25	Ukázka zašuměných klinických snímků z databáze krk šumem typu Speckle. . . .	49
26	Haar vlnka	50
27	Jednotlivé druhy vlněk rodiny Daubechies	51
28	Jednotlivé druhy Symlets vlněk	51
29	Základní fáze 2D vlnkovy transformace pomocí banky filtrů	53
30	Základní fáze 2D vlnkovy transformace pomocí banky filtrů	55
31	Porovnání výsledků filtrace Gaussovského šumu pomocí vlněk rodiny Daubechies pro snímky z databáze břicho.	58
32	Porovnání výsledků filtrace Gaussovského šumu pomocí vlněk rodiny Daubechies pro snímky z databáze karotidy.	60

33	Porovnání výsledků filtrace Gaussovského šumu pomocí vlnek rodiny Daubechies pro snímky z databáze krk.	62
34	Výstup filtrovaného obrazu zašuměného Gaussovským šumem.	63
35	Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlnek rodiny Daubechies pro snímky z databáze břicho.	65
36	Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlnek rodiny Daubechies pro snímky z databáze karotidy.	67
37	Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlnek rodiny Daubechies pro snímky z databáze krk.	69
38	Výstup filtrovaného obrazu zašuměného Salt and Pepper šumem.	71
39	Porovnání výsledků filtrace Speckle šumu pomocí vlnek rodiny Daubechies pro snímky z databáze břicho.	73
40	Porovnání výsledků filtrace Speckle šumu pomocí vlnek rodiny Daubechies pro snímky z databáze karotidy.	75
41	Porovnání výsledků filtrace Speckle šumu pomocí vlnek rodiny Daubechies pro snímky z databáze krk.	77
42	Výstup filtrovaného obrazu zašuměného Speckle šumem.	78
43	Výstup filtrovaného obrazu zašuměného Speckle šumem.	79
44	Výstup filtrovaného obrazu zašuměného Speckle šumem.	80
45	Porovnání efektivity filtrace Speckle šumu pomocí vlnek rodiny Daubechies a Symlets o rozdílných úrovní rozkladu pro snímky z databáze břicho.	82
46	Porovnání efektivity filtrace Speckle šumu pomocí vlnek rodiny Daubechies a Symlets o rozdílných úrovní rozkladu pro snímky z databáze karotidy.	84
47	Porovnání efektivity filtrace Speckle šumu pomocí vlnek rodiny Daubechies a Symlets o rozdílných úrovní rozkladu pro snímky z databáze krk.	86
48	Vybraný ultrazvukový snímek z databáze břicho k subjektivnímu posouzení efektivity filtrace.	88
49	Přiblížené oblasti zájmu vybraného ultrazvukového snímku z databáze břicho k subjektivnímu posouzení efektivity filtrace.	89

Seznam tabulek

1	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze břicho.	57
2	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze karotidy.	59
3	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze krk.	61
4	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze břicho.	66
5	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze karotidy.	68
6	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze krk.	70
7	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze břicho.	72
8	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze karotidy.	74
9	Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze krk.	76
10	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Daubechies pro UZ snímky databáze břicho.	81
11	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Symlets pro UZ snímky databáze břicho.	83
12	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Daubechies pro UZ snímky databáze karotidy.	83
13	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Symlets pro UZ snímky databáze karotidy.	85
14	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Daubechies pro UZ snímky databáze krk.	85
15	Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Symlets pro UZ snímky databáze krk.	87
16	Tabulka znázorňující časovou náročnost algoritmu filtrace pro Gaussův šum.	87
17	Tabulka znázorňující časovou náročnost algoritmu filtrace pro Salt and Pepper šum.	87
18	Tabulka znázorňující časovou náročnost algoritmu filtrace pro Speckle šum.	87

Úvod

Ultrasonografie je jedna z široce používaných diagnostických zobrazovacích metod. Je neinvazivní a patří mezi velice účinné formy zobrazování. Tato metoda je velice přijatelná pro pacienta, protože je rychlá, bezbolestná a relativně levná, ve srovnání s jinými zobrazovacími modalitami. Jednou z hlavních nevýhod ultrazvukového obrazu je špatná kvalita obrazu způsobená Speckle šumem. Kvůli Speckle šumu, je ultrazvukové vyšetření značně komplikovanější, a proto pouze zkušený radiolog může účinně diagnostikovat. Kromě toho přítomnost Speckle šumu komplikuje úlohy zpracování obrazu, jako je například segmentace. Proto je potlačení nezbytné jak pro zlepšení kvality obrazu, tak i zvýšení zisku diagnostického potenciálu ultrazvukového vyšetření. Bylo vyvinuto mnoho technik pro redukci šumu, které zároveň zachovávají detaily v ultrazvukových obrazech. Mezi jednu z těchto metod, které se jeví jako velice efektivní patří vlnková transformace. Během posledních dvou desetiletí se ultrazvukové zařízení stalo kompaktnějším, kvalitnějším a levnějším [1, 2].

Práce je rozdělena na teoretickou a experimentální část. V teoretické části je shrnut současný stav problematiky filtrace Speckle šumu z ultrazvukových obrazů. Vytvořená rešerše se skládá z aktuálních poznatků, a to především z odborných zahraničních článků. Diplomová práce je primárně zaměřena na filtraci šumu z ultrazvukových obrazů pomocí vlnkové transformace.

Kapitola 1 je zaměřena na popis problematiky ultrasonografie. Jsou zde vysvětleny principy ultrasonografie, základní módy ultrazvukového zobrazování a artefakty, které mohou nastat. Následující kapitola 2 je věnována popisu obrazové filtrace. Zde jsou objasněny základní principy obrazu, typy filtrací a následně možné hodnocení kvality obrazové filtrace. Kapitola 3 se zaměřuje na popis jednotlivých typů šumů, které jsou následně filtrovány v praktické části, a nastudování pokročilejších metod pro eliminaci šumu z ultrazvukových obrazů.

Praktická část diplomové práce je v prvním úseku zaměřena na tvorbu testovací databáze a implementaci šumových generátorů na vytvořená klinická data. Jsou zde vytvořeny tři testovací databáze, které obsahují celkově 220 ultrazvukových klinických obrazů. Šumové generátory jsou vytvořeny pro tři typy variantních šumů, u kterých je nastaveno dvacet rozdílných úrovní zašumění. Jako typy šumu jsou zvoleny Gaussovský, Salt and Pepper a zejména Speckle šum. Dále je zde popsán ultrazvukový přístroj, pomocí kterého byla data vygenerována. Poté je část zaměřena na teoretickém úvodu vlnkové transformace.


Experimentální část této práce je zaměřena na studii dynamiky uměle aplikovaného šumu pro filtraci kooperativních vlnek vlnkové transformace. Filtrace je porovnávána pomocí objektivních parametrů a je proveden závěr.

1 Ultrasonografie

Ultrazvuk je termín používaný k popisu frekvence zvuku přesahující 20 000 Hz, která je pro lidské ucho takřka neslyšitelná [3]. Ultrazvukové vlny mohou vznikat a šířit se, kvůli existenci mezivazebných sil částic látky, a jsou popsány parametry **tlakové denzity**, **směru šíření** a **posunem částic**.

Pokud je posun částic souběžný se směrem šíření, je možno uvažovat o **podélném** (longitudálním) vlnění, které je typické v měkkých tkáních a tekutinách lidského organismu. Jestliže je směr šíření kolmý, lze hovořit o **příčném** (transverzálním) vlnění, typické pro pevné látky, například kosti. Interakce ultrazvukových vln s tkáněmi podléhá zákonům geometrické optiky. Obsahuje **odraz**, **lom**, **rozptýlení**, **difrakce**, **interference** a **absorpce** (viz obr. 1). Všechny interakce, s výjimkou interference, snižují intenzitu ultrazvuku [4–6]. Hlavní charakteristikou ultrazvukové vlny je její vlnová délka λ , udávající míru vzdálenosti mezi minimální a maximální hodnotou sinusové křivky, a frekvence f , udávající počet vln za jednotku času. Pomocí těchto dvou veličin je možno určit rychlost šíření ultrazvukových vln v [6]:


$$v = \lambda \cdot f \quad (1)$$



Obrázek 1: Interakce s prostředím [4]

Ultrazvukové techniky jsou především založeny na měření ozvěn odražených od média, ke kterému byly vyslány. V medicínské ultrazvukové diagnostice se používají především dva principy, **echo impulzní technika** a **Dopplerovská technika**. V echo impulzní technice ultrazvuková vlna interaguje s tkáněmi a krví, kde část přenášené energie se vrací zpět k měniči, kterým je zpracována. Pokud je známa rychlost šíření ve vyšetřované tkáni, je možno určit její vzdálenost od měniče. Charakteristické rysy odraženého signálu, jako například amplituda, fáze a jiné, nám poskytují informace o povaze interakce, dle kterých lze stanovit typ média, ve kterém se vyskytly [6].

Dopplerovská technika využívá tzv. Dopplerova jevu, který byl poprvé popsán rakouským vědcem Christianem Dopplerem. Efekt je zodpovědný za změny frekvence vln emitovaných pohyblivými objekty, které zkoumá stacionární pozorovatel. Vnímaná frekvence je vyšší, pokud se objekt pohybuje směrem k pozorovateli a nižší, pokud směrem od něj (viz obr. 2) [3].



Obrázek 2: Dopplerův efekt [5]

Jak si lze povšimnout na obr. 2 při klidném stavu mezi pozorovatelem a zdrojem vlnění nedochází ke změně vnímané frekvence (a). Avšak bude-li zdroj vlnění nebo jeho pozorovatel v pohybu, dochází ke změně frekvence vlnění, která je způsobena nahušťováním, potažmo zředováním vlnoploch vlnění ve směru pohybu zdroje či pozorovatele (b) [5].

Dopplerovský posun je nazýván rozdíl ve frekvenci Δf , která se zvyšuje s rychlostí pohybu jícího se objektu. Závisí na emitované frekvenci f , rychlosti pohybu tkáně v , rychlosti vlnění c a úhlu α mezi pozorovatelem a směrem pohybu emitoru. V lékařství se dopplerovské techniky používají zejména k analýze průtoku krve. Pozorovaná Dopplerovská frekvence může být použita pro výpočet rychlosti krevního řečiště (viz 2 [3]), jelikož rychlost ultrazvuku je předem známá, úhel mezi cévou(cévami) a sondou může být zjištěn během samotného měření, což dovoluje případnou nápravu. Je nutno poznamenat, že k této situaci dochází dvakrát, poprvé kdy paprsek zasáhne pohyblivé krevní elementy, a po druhé když jsou vlny buňkami odraženy.

$$v = c \cdot \frac{\Delta f}{2f} \cdot \cos \alpha \quad (2)$$

Při použití zvukových kmitočtů 2 až 10 MHz, fyziologický průtok krve způsobuje Dopplerův posun v řádech 50 až 16 000 Hz [3].

1.1 Módy ultrazvukového zobrazování

Ultrazvukové zobrazování zahrnuje širokou škálu zobrazovacích režimů a technik, které využívají interakce zvukových vln s živými tkáněmi pro vytvoření obrazu tkání, nebo v případě režimů založených na Dopplerovském zobrazení určují rychlost pohybující se tkáně, především krve [7].


1.1.1 A-Mód

Jedná se o nejjednodušší jednorozměrnou vyšetřovací metodu ultrazvukového obrazu, která funguje na principu amplitudové modulace. Principem metody je zaznamenávání amplitud elektrických signálů na převodníku s jediným krystalem. Na monitoru jsou zobrazeny odrazy ultrazvukových vln vytvářející signál výchylek v obraze, které odpovídají místu odrazu ve tkáni. Velikost amplitudy je závislá na množství odražené akustické energie. V současnosti se s A-módem lze setkat zřídka, jelikož získané informace jsou omezené. Uplatnění je možno nalézt například v oftalmologii [3, 5].

1.1.2 B-Mód

Jedná se o nejpoužívanější metodu v ultrazvukovém diagnostickém zobrazování, které poskytuje dvourozměrný obraz vyšetřované oblasti [8]. Odrazy jsou na monitoru zobrazeny v podobě světelných bodů (pixelů), kde jas každého pixelu odpovídá velikosti odrazů ultrazvukových vln. Pro zobrazení jednotlivých pixelů se běžně používá škála o 256 odstínech šedi, kde světlejší pixel odpovídá silnějšímu odrazu, a jeho poloha odpovídá místu v měřené oblasti. U moderních ultrazvukových přístrojů se lze setkat i s nastavitelnou barevnou škálou [5]. Pro hodnocení odrazivosti nebo-li **echogenity** tkání jsou definovány termíny jako **hypoechogenní**, **hyperechogenní**, **anechogenní** a **izoechogenní** (viz obr. 3).

Hypoechogenní struktury jsou tmavší pixely, jelikož vykazují slabé odrazy ultrazvukového paprsku, např. měkké tkáně, či patologická ložiska. Opakem jsou hyperechogenní objekty, vyobrazeny světlejšími pixely z důvodu silnějších odrazů UZV paprsku. Typickým příkladem jsou kosti nebo kalcifikace. U anechogenních objektů, zobrazeny bez jasu, nedochází k odrazům. Tento jev je způsoben odrazem od tekutiny vyskytující se v cystách či orgánových dutinách. Pro struktury, které jsou neodlišitelné od okolních pixelů, je používán pojem izoechogenní. Pokud dojde k odrazení veškerých UZV vln, dochází k tzv. akustickému stínu, který znemožňuje hodnocení hlubších objektů [5, 9].



Obrázek 3: Příklady různých echogenních struktur [10]

Na obr. 3 lze vidět játra se střední echogenitou, kde jsou patrné anechogenní útvary odpovídající cystám (a). Uprostřed je možno pozorovat pod játry silné odrazy anechogenního žlučníku, což je typické pro konkrement, který vytváří akustický stín (b). Na posledním snímku lze sledovat hyperechogenní útvar odpovídající hemangiomu (c) [10].


1.1.3 M-Mód

Jiným názvem TM(time-motions), se používá při diagnostice pohybujících struktur, zejména pro potřeby kardiologického vyšetření, jako součást echokardiografie. Jedná se o dynamické zobrazení vyšetřované oblasti rozložené v čase, které je principiálně podobné jako A-mód, avšak s tím rozdílem, že se křivka výchylek kontinuálně překresluje v čase podle zvolené frekvence. Modernější systémy dokáží pracovat s frekvencí okolo 5 000 Hz, proto je možné zachytit velmi rychlé pohyby, například srdečních chlopní [3, 5].

1.1.4 Dopplerovské zobrazení

Tyto techniky zakládají na principu Dopplerova jevu popsáného výše, viz kapitola 1. Dopplerovské zobrazení, jak již bylo řečeno, se využívá k měření pohyblivých struktur, například krvinek [3]. Mezi hlavní režimy zobrazení moderního Dopplerovského systému patří **spektrální Doppler** a **2D barevné zobrazení**.

U **spektrálního Doppleru** jsou veškeré informace zjištěné o rychlosti z cévy podél jediného ultrazvukového svazku vyobrazeny pomocí frekvence a času (viz obr. 4). Jak si lze povšimnout na obrázku vertikální vzdálenost zobrazuje Dopplerovský posun, zatímco stupnice šedi indikují amplitudu detekovaného ultrazvuku s danou frekvencí.



Obrázek 4: Zobrazení spektrálního Dopplera femorální tepny [11]

Narozdíl od **2D barevného zobrazení** jas barvy indikuje funkci rychlosti toku, neboli Dopplerův posun pro každý pixel. Výhodou 2D barevného zobrazení je, že umožňuje uživateli

sledovat přítomnost průtoku krve v celé ploše tkáně. Zatímco spektrální Dopplerové zobrazení umožňuje bližší kontrolu změn rychlosti v čase u jediné malé oblasti.

Jak spektrální, tak barevný Dopplerovský systém využívají Dopplerova jevu pro získání informací o toku krve. Oba tyto způsoby se navzájem doplňují a poskytují uživateli širokou škálu užitečných informací [11].

Některé ultrazvukové Dopplerovské systémy jsou známy jako systémy s **kontinuální vlnou (CW)**, nepřetržitě vysílající ultrazvukovou vlnu. Jiné jako **pulsní (PW)**, které přenášejí krátké pulsy. Hlavní výhodou PW Dopplera je, že lze signály získat ze známé hloubky, avšak oproti tomu je hůře odhadována vyšší rychlosti. Jelikož veškeré ozvěny přicházejí na snímač mezi impulsy v určitém časovém intervalu, kdy jsou analyzovány [3, 11]. K vysílání i příjmu totiž slouží pouze jeden piezoelektrický měnič [5]. Obecným problémem se všemi pulzními Dopplerovými technikami je analýza vysokých rychlostí, jelikož rozsah pro měření Dopplerovských frekvencí je omezen frekvencí opakování impulsů. Pokud tento děj nastane, že Dopplerovská frekvence je vyšší než frekvence opakování impulsů, tak se vysoké rychlosti zobrazují jako nízké, v opačném směru (u spektrálního Dopplera), anebo v nesprávné barvě (barevný Doppler) [3, 11]. PW Dopplery nachází v medicíně uplatnění zejména k měření rychlosti a odlišení krevního toku laminárního od turbulentního, či naopak. Laminární proudění je na spektrální křivce uspořádané, oproti tomu turbulentní je typické chaotickým uspořádáním spektra [5].

U systému CW Dopplera musí být samostatný přenos a příjem ultrazvuku, čehož je docíleno pomocí dvou měničů. Jeden, který nepřetržitě přijímá, a druhý, který nepřetržitě vysílá [3, 11]. Oba měniče jsou vůči sobě skloněny v tupém úhlu. Jelikož je ultrazvuk u tohoto systému vysílán kontinuálně, neuplatňuje se zde opakovací frekvence, která limituje při měření vyšších rychlostí. Avšak na druhou stránku, není možno odlišit odrazy signálů z různých hloubek a naměřený signál může obsahovat informace z více cév současně. CW Dopplery nachází v medicíně uplatnění zejména k detekci rychlosti krevního řečiště v cévách uložených blízko pod kůží [5].

1.1.5 3D a 4D techniky

Hlavními důvody výzkumu 3D metody, byla snaha o překonání omezení 2D ultrazvukového zobrazení, které jsou především ve ztrátě objemové jednotky plošného 2D obrazu. Toho lze dosáhnout matematickou rekonstrukcí z nasnímaných plošných obrazů, které je možno získat posunem, nakláněním anebo rotací sondy. 3D modalita poskytuje lepší prostorové zobrazení pro různé intervenční postupy, jako například biopsie [4, 12]


Pokud je možno nasbíraná data zpracovávat vysokou rychlostí, je získáno dynamické 3D zobrazení, neboli zobrazení v reálném čase, které se nazývá 4D. Hlavní výhodou je přehlednější a intuitivnější orientace v 3D prostoru. Nejčastější uplatnění nachází tyto techniky v porodnictví a ortopedii [3, 12].

1.2 Artefakty v ultrasonografii

Artefakty jsou rysy ultrazvukového obrazu, které neodpovídají skutečným strukturám, například nereprezentují skutečné akustické rozhraní s ohledem na tvar, intenzitu nebo polohu. Artefakty mohou nepříznivě ovlivnit kvalitu obrazu, a tak mohou vést k chybné diagnóze, avšak ve většině případů nejsou obtížně rozpoznatelné. Původ artefaktů lze zejména nalézt v konstrukci vyšetřovacích sond, vzájemném působení ultrazvukového signálu s vyšetřovanou tkání, anebo při nesprávné manipulaci, která je závislá na zkušenostech a znalostech vyšetřujícího klinika, které pochází především ze znalostí fyzikálních principů vzniku ultrazvukového obrazu [3, 4].

1.2.1 Reverberace

Jedná se o opakované odrazy patřící mezi časté artefakty. Lze je rozdělit na vnitřní odrazy (odražené na rozhraní), a nebo na povrchu samotného měniče, přičemž se ozvěny po každém odrazu stávají slabšími. Struktury, které způsobují vnitřní odrazy, jsou zobrazovány dvakrát nebo vícekrát na vícenásobné vzdálenosti od převodníku, vždy ve stejném pořadí jako původní konstrukce, ale slabší. Tyto echa jsou obzvláště nápadné ve strukturách bez ozvěny, například cysty [3].




Obrázek 5: Ukázka reverberace [11]

Na obr. 5 lze vidět generování reverberací, když je odraz z silně odrazivého rozhraní částečně odražen od povrchu snímače zpět na rozhraní(a). Reverberace zobrazená v oblasti močového měchýře(b) [11].

1.2.2 Zrcadlový artefakt

Paprsek dopadá na vysoce reflexní rozhraní, které odráží paprsek ke straně, kde způsobuje další odrazy nebo zpětný rozptyl. Tyto ozvěny jdou stejnou cestou zpět k převodníku, kde jsou nesprávně zobrazeny v původním směru paprsku. S těmito artefakty se lze setkat pouze v anechogenních oblastech, typickým příkladem je léze jater, kde zrcadlový artefakt může být mylně interpretován jako léze plic [3].



Obrázek 6: Zrcadlový artefakt [11]

Na obr. 6 je možno vidět zrcadlový obrazový artefakt, který se může vyskytnout za silně odrazujícím rozhraním. Rozptýlené ozvěny z cílů před rozhraním jsou přijímány přes odraz na rozhraní. Ty jsou zobrazeny v přímém směru za rozhraním(a). Na obrázku je zobrazena jaterní ozvěna za bránicí(b) [11].

2 Obrazová filtrace a její hodnocení

Zpracování obrazu je doména, která se točí kolem provádění operací na digitálních snímcích. Ty se mohou lišit od rozmazání obrazu k ostření. Oblast medicíny těží z integrace takových modelů při předzpracování, vylepšení a extrakce obrazu, které jsou široce používány k analýze specifických dat k detekci jakékoliv abnormality z daného obrazu či neobvyklých událostí. Tyto obrazy poté mohou být použity k detekci a následné léčbě všech možných škodlivých onemocnění v lidském těle. Lékařské snímky jsou během akvizice a přenosových fází vystaveny více problémům, zejména obrazovému zkreslení v důsledku šumu, což činí jeho odstranění důležitým krokem ve zpracování medicínských obrazů. K tomu lze využít řadu různých filtrů [13].

2.1 Charakteristika obrazu

Obraz je možno definovat geometricky jako průmět sledovaného objektu do roviny sítnice oka, nebo jako zrakový vjem vzniklý po dopadu světla na sítnici oka. Matematicky lze chápat jako vícerozměrný signál (obrazovou funkci), popsanou několika proměnnými [5]. Obrazová funkce u 2D monochromatického obrazu je definovaná jako [14]:

$$f = (x, y) \quad (3)$$

kde x a y značí prostorové souřadnice v jednotlivých bodech obrazu a f je hodnota přiměřená jasu v těchto bodech.

Obrazová funkce viz 3 nemusí být pouze skalární, ale její hodnoty mohou být také vektory, u barevného obrazu složky RGB modelu. Pro zpracování obrazu se musí snímek nejdříve digitalizovat, neboli rozložit na body tzv. pixely, kterým je přidělena kvantová hodnota odpovídající jasu bodu v původní obrazové funkci. Tento digitalizovaný obraz lze matematicky popsat maticí [5, 14]:

$$\mathbf{f(i,j)} = \begin{pmatrix} f(0,0) & f(0,1) & \cdot & \cdot & f(0,N-1) \\ f(1,0) & f(1,1) & \cdot & \cdot & f(1,N-1) \\ \cdot & \cdot & & & \\ f(N-1,0) & f(N-1,1) & \cdot & \cdot & f(N-1,N-1) \end{pmatrix} \quad (4)$$

Kde f , i , j jsou digitálními hodnotami a N určuje počet řádků a sloupců matice odpovídající počtu pixelů v obraze [14].

2.1.1 Vlastnosti obrazu

Obraz je možno popsat jako celek tzv. **globální charakteristiky**, nebo jenom jeho určité oblasti **lokální charakteristiky**. Tyto dvě zmíněné charakteristiky se liší ve znalosti vzájem-

ných poloh pixelů v obraze (u lokální charakteristiky). Vlastnosti lze popsat pomocí:

- **Hloubky obrazu**, počet bitů vyhrazených pro jeden obrazový bod, který může nabývat například 256 hodnot při 8 bitech, či $16, 7 \cdot 10^6$ u 24 bitech.
- **Dynamického rozsahu**, lze vyjádřit jako poměr nejtmašího pixelu (H_{min}) ku nejsvětlejšímu (H_{max}), přičemž $H = f(x, y)$ nebo vyjádřením v decibelech (dB) v logaritmickém měřítku [5]:

$$DR = 20 \log \frac{H_{max}}{H_{min}} \quad (5)$$

DR označuje dynamický rozsah, konstanta 20 vychází z teorie Weber-Fechnerova zákona a definice decibelu, H_{max} pixel nejsvětlejší v obraze zatímco H_{min} nejtmaší.

- **Jasu**, který vyjadřuje střední hodnotu všech obrazových bodů v obraze matematicky popsaných jako aritmetický průměr, či medián. Pro RGB model lze vypočítat pomocí vzorce [5]:

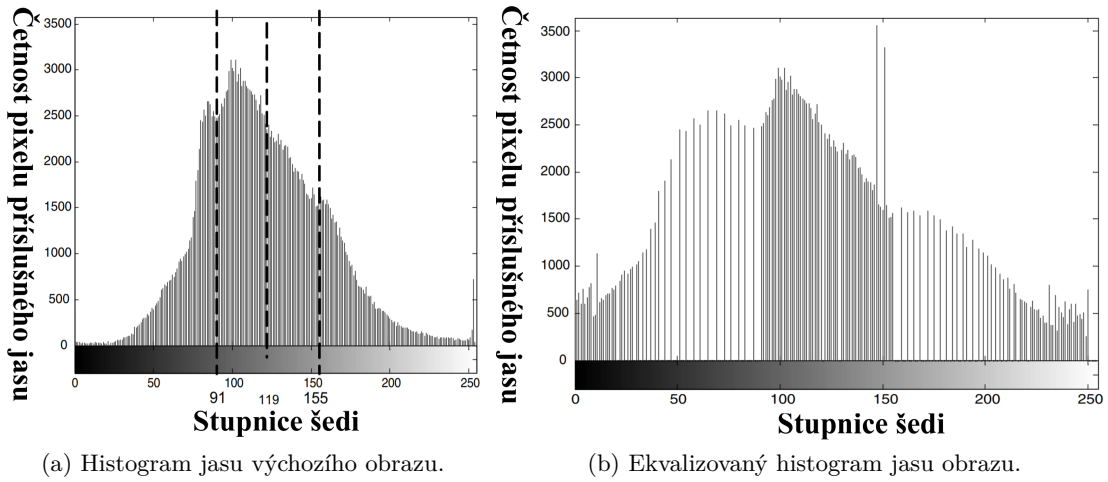
$$I = 0,299R + 0,587G + 0,114B \quad (6)$$

- **kontrastu**, určující rozsah rozdílnosti dvou pixelů v obraze, který lze vypočítat jako [5]:

$$K = \frac{I_1 - I_2}{I_1 + I_2} \quad (7)$$

K značí kontrast, I míra odlišnosti hodnot.

Mezi další parametry popisující vlastnosti obrazu patří **histogram**, který vyjadřuje jednotlivé četnosti stupňů jasu v obraze. Slouží k vizuálnímu hodnocení kvality obrazu. Jedná se o graf, který dle své šířky popisuje kontrast obrazu. Pokud je posunut doleva, svědčí o tmavém (tzv. podexponovaném), doprava o světlém (tzv. přexponovaném) obraze. Pokud bude požadováno zvětšení kontrastu obrazu, je možno tak provést roztážením histogramu na větší rozsah jasu pixelů. Kdy počet jasových úrovní se nemění, ale hodnoty jasu některých pixelů se přemění. Jedná se o tzv. **ekvalizaci histogramu** znázorněnou na obr. 7. Kde obr. 7 a) vyjadřuje histogram výchozího obrazu a obr. 7 b) ekvalizovaný histogram téhož obrazu [5, 14].



Obrázek 7: Ekvalizace histogramu [15]

2.2 2D cyklická konvoluce

Jedná se o poměrně častou matematickou operaci využívanou při zpracování obrazu, označovanou symbolem $(*)$. Principiálně jde o operaci dvou vstupních signálů (obrazů) kterékoliv dimenze. Transformační funkci označovanou $h_{(x,y)}$ lze interpretovat jako konvoluční jádro, které v případě diskrétní konvoluce lze chápat jako matici hodnot, tzv. konvoluční masku. Maska v daném místě obrazu násobí hodnoty pixelu daným koeficientem, přičemž sečtením všech hodnot je možno dostat výslednou hodnotu pixelu výstupního obrazu, nejčastěji dosazenou do středu konvoluční masky [5, 16].

Konvoluce obrazu $f(x, y)$ s operátorem $h(x, y)$ a výsledným obrazem $g(x, y)$ je dána [17]:

$$g(x, y) = h(x, y) * f(x, y) \quad (8)$$

Konvoluční teorém uvádí, že konvoluce v prostorové oblasti je ekvivalentní násobením frekvenční oblasti. Z toho vyplývá, že [17]:

$$G(u, v) = H(u, v)F(u, v) \quad (9)$$

Kde $G(u, v)$, $H(u, v)$ a $F(u, v)$ značí Fourierovou transformaci $g(x, y)$, $h(x, y)$ a $f(x, y)$. Vhodnou volbou $h(x, y)$, lze získat výsledný obraz $g(x, y)$ a to jako vylepšenou verzi původního obrazu $f(x, y)$ [17].

Diskrétní konvoluce ve 2D obrazu je definovaná vztahem [5]:

$$f(x, y) * h(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k f(x-i, y-j) \cdot h(i, j) \quad (10)$$

2.3 Typy filtrace

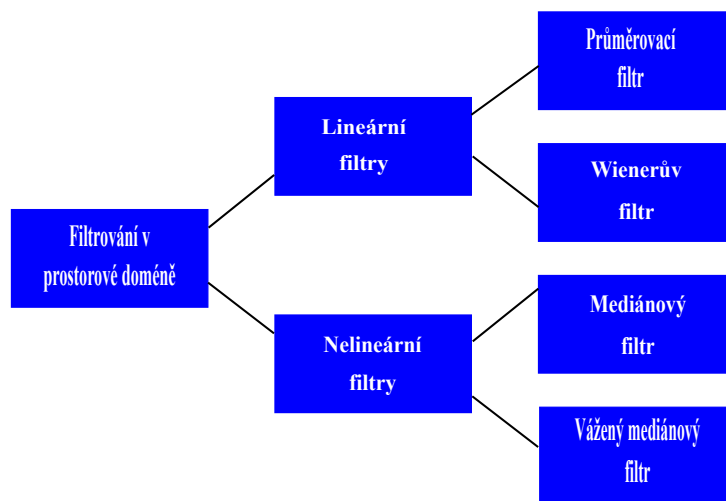
Filtry hrají velmi důležitou roli v procesu potlačení rušivých složek obrazu. Použitím metod filtrování se při rozhodování o určité hodnotě pixelu podílí i sousední obrazové body. Tyto hodnoty ve filtru jsou spíše brány jako koeficienty. Filtr, který lze použít pro potlačení rušivých složek obrazu, je také nazýván jako maska. Existují dva základní přístupy pro utlumení disruptivních složek:

- metody filtrování v prostorové doméně
- filtrování pomocí transformace

Tyto metody mohou být buď **lineární** nebo **nelineární**. Lineární metody jsou dostatečně rychlé, avšak nezachovávají detaily obrazu oproti nelineárním.

2.3.1 Metody filtrování v prostorové doméně

Proces prostorového filtrování spočívá v jednoduchém pohybu masky filtru z bodu na bod obrazu, který se v tomto pixelu přepočítá pomocí předem definovaného vztahu. Při lineárním prostorovém filtrování je hodnota výchozího pixelu lineární kombinací hodnot vstupního pixelu a jeho okolí. Přehledné rozdělení metod filtrace v prostorové doméně viz obr. 8 budou následně jednotlivě popsány [18, 19].



Obrázek 8: Klasifikace filtrace v prostorové doméně [18]

Průměrovací filtr

Pojednává o tradičním způsobu filtrování, který obraz vyhlazuje snižováním rozdílu intenzit okolních pixelů. Průměrovací filtr je jednoduchý prostorový filtr, nahrazující střední hodnotu pixelu průměrem sousedských obrazových bodů, pomocí pohybujícího se okna. To je realizováno

konvoluční maskou, která poskytuje výsledek váženým součtem hodnot pixelu a jeho sousedních pixelů. Průměrovací filtr je používán k potlačení aditivního šumu (popsaného v kapitole 3.1) [18]. Lze matematicky definovat jako [20]:

$$\hat{f}(x, y) = \frac{1}{mn} \sum_{(s,t) \in S_{xy}} g(s, t) \quad (11)$$

Kde S_{xy} představuje množinu souřadnice v okně obdélníkového podobrazu velikosti $m \times n$ se středem v bodě (x, y) . Proces průměrového filtrování vypočítá průměrnou hodnotu poškozeného obrazu $g(x, y)$ v oblasti definované S_{xy} . Jinak řečeno hodnota obnoveného obrazu \hat{f} v libovolném bodě (x, y) je prostým aritmetickým průměrem vypočítaný z oblasti pixelů definovaných S_{xy} . Tato operace může být realizována pomocí konvoluční masky, ve které mají všechny koeficienty hodnotu $\frac{1}{mn}$. Jednoduše řečeno průměrovací filtr vyhlazuje místní změny v obraze, šum se snižuje v důsledku rozmazání [20].

Wienerův filtr

Jedná se o filtr prostorové domény, obecně používaný k potlačení aditivního šumu. Wienerovy filtry jsou třídou optimálních lineárních filtrů, které zahrnují lineární odhad požadované signální sekvence z jiné příbuzné sekvence. Hlavním účelem je snížení množství šumu přítomného v obraze srovnáním odhadovaného požadovaného obrazu bez šumu. Tyto filtry jsou charakterizovány následovně:

- **Předpoklad**, signál a aditivní šum jsou stacionární lineární náhodné procesy se známými spektrálními charakteristikami.
- **Požadavek**, filtr musí být fyzicky realizovatelný, kauzální.
- **Kritéria výkonu**, musí být minimální střední kvadratická chyba.

Wienerova filtrace je dána vztahem [18]:


$$\hat{F}(x, y) = \bar{g} + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_n^2} (g(x, y) - \bar{g}) \quad (12)$$

$\hat{F}(x, y)$ značí obnovený obraz, σ_f^2 je lokální rozptyl a σ_n^2 rozptyl šumu [18, 21].

Mediánový filtr

Pokud je prováděno utřídění velikosti všech vektorů v masce, dle jejich velikosti. Obrazový bod se střední hodnotou nahrazuje pixel zájmu. Mediánové filtry jsou poměrně populární, jelikož u některých typů náhodného šumu poskytují vynikající možnosti redukce šumu s výrazně menším rozostřením než u lineárních vyhlazovacích filtrů [20, 21]. Cílem je prozkoumat vzorek vstupního signálu a rozhodnout, zda-li je reprezentativní. Tuto operaci provádí okno, sestavené z lichého

počtu vzorků seřadovací hodnoty v číselném pořadí, kde výstupem je zvolena střední hodnota (viz obr. 9). Tento typ filtru je zejména užitečný při redukci šumu typu Salt and Pepper (popsaného v kapitole 3.1) [22].



Obrázek 9: Grafické znázornění operace mediánového filtru [23]

Tento filtr na obr. 9 analyzuje sousední obrazové body kolem počátečního pixelu, kdy pro tento případ bylo použito okno 3x3 pixelů. Jak je vidět, tak hodnoty pixelů v okně jsou seřazeny ve vzestupném pořadí. Poté je zvolena střední hodnota, v tomto případě 50, která nahrazuje ve výstupním obraze původní hodnotu 70 [23].

Mediánový filtr lze matematicky formulovat [18]:

$$G_{(n)} = Med[F_{(n-k)} \dots F_{(n)} \dots F_{(n+k)}] \quad (13)$$

kde $G_{(n)}$ a $F_{(n)}$ jsou vstupní a výstupní sekvence [18].

Vážený mediánový filtr

Poskytuje zachování specifikovaných požadovaných vlastností obrazu, jelikož oproti klasického mediánového filtru se dá nastavit vliv dat, které se nacházejí na určitých místech filtrovacího okna. Tímto je možno zamezit ztrátě relevantních detailů původního signálu, jako při klasickém mediánovém filtru. Je založen na přiřazování větší váhy některým datům při hledání mediánu ze všech hodnot filtrovacího okna. Z hodnot nacházející se na určitých pozicích filtrovacího okna se po několikanásobném opakování vypočítá medián, kde počet opakování je závislý na kladných celých číslech, neboli vah označené W_i [24, 25]

V případě diskrétního vstupního vektoru hodnoty $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N)$ je výstup váženého mediánového filtru Y spojený s N počtem vážených celočíselných vah $\mathbf{W} = (\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_N)$ je dán [18]:

$$Y = MED[W_1 \cdot X_1, W_2 \cdot X_2, \dots, W_N \cdot X_N] \quad (14)$$

Kde MED označuje mediánovou operaci, W_N váhu N vzorku a X_N hodnotu N vstupního prvku. Takže postup uvnitř okna filtru lze konstatovat jako vynásobení každého prvku X_N a zvolení hodnoty mediánu z nové sekvence [18].

2.3.2 Filtrování pomocí transformace

Tento typ filtrace je na rozdíl od prostorové oblasti efektivnější, jelikož dokáže identifikovat šum již ve frekvenční doméně. Pokud je obraz přeměněn pomocí Fourierovy transformace, nízkofrekvenční složky obvykle odpovídají hladkým nebo rozostřeným strukturám obrazu, zatímco vysokofrekvenční komponenty představují detaily obrazu, hran a šumu. Díky tomu lze navrhnout filtry podle části obrazové frekvence pro plynulý obraz nebo pro odstranění šumu [18].

2.4 Subjektivní a objektivní hodnocení obrazové kvality

Jak již bylo řečeno v úvodu této kapitoly, během zachycení, přenosu nebo zpracování může dojít ke snížení kvality obrazu. Měření kvality obrazu může pomoci při posouzení stupně degradace. Požadovaná kvalita přirozeně závisí na účelu, ke kterému je obraz používán. Metody hodnocení kvality obrazu lze rozdělit do dvou kategorií, **subjektivní** a **objektivní** [26].

2.4.1 Subjektivní hodnocení kvality obrazu

Jedná se o primární hodnocení kvality obrazu, buďto jedním nebo více pozorovateli. Mezi metody subjektivního hodnocení snímků patří průhlednost, zvolení barevných kanálů, či detekování hran jednotlivých pixelů, kde je posuzován registrovaný obraz vzhledem k obrazu referenčnímu. Subjektivní hodnocení je také závislé na celkových znalostech, zkušenostech a únavě pozorovatele [27, 28].

K tomu aby bylo možno navrhnout přesné a spolehlivé indikátory kvality obrazu, je nutné pochopit, co kvalita znamená pro odborníka, přičemž spokojenost je závislá na mnoha faktorech. Jedním z nejdůležitějších je samozřejmě obsah obrazu. Mezi další důležité parametry se řadí vzdálenost pozorování, velikost zobrazení, rozlišení, jas, kontrast, ostrost a barevnost. Psychologické výzkumy ukazují, že při hodnocení obrazu odborníky, existují významné rozdíly mezi vnímáním kontrastu a dalšími kritickými vizuálními parametry [6].

MOS¹

Jedná se o subjektivní metodu hodnocení kvality lékařského obrazu, která popisuje, jak dobře poskytuje diagnostické informace odborníkovi. Provádí se pomocí testů nebo dotazníků s číselným hodnocením. Předkládá se náhodná sada obrázků, a hodnotí se pomocí stupnice od 1 až 5, kde 1 značí špatnou kvalitu a 5 kvalitu vynikající. Následně lze použít statistickou analýzu dle vztahu [29]:

$$MOS(k) = \frac{1}{M} \sum_{i=1}^M S(i, k) \quad (15)$$

¹Mean Opinion Score - střední hodnota názoru.

Kde $S(i, k)$ je vyhodnocovací skóre obrazu k pozorovatelem i . M značí počet pozorovatelů [29].

2.4.2 Objektivní hodnocení kvality obrazu

Cílem je navrhnout matematické modely, které jsou schopné přesně a automaticky predikovat kvalitu obrazu tak, aby se ideálně rovnali hodnocení odborníka. Jejich využití je možno najít například při porovnávání algoritmů zpracování obrazu, kde lze posuzovat, zda-li je výsledná kvalita při použití daného algoritmu vyšší než ta původní. Jednotlivé metody objektivního hodnocení kvality obrazu budou následně popsány [27].

MSE²

Jedná se o průměrnou kvadratickou odchylku mezi dvěma datovými vzorky, např. referenčním a zkušebním obrazem. Pokud je uvažováno nad obrazem v okně $M \times N$ lze matematicky vyjádřit jako [6]:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (g_{i,j} - f_{i,j})^2 \quad (16)$$

Kde $g_{i,j}$ značí originální obraz a $f_{i,j}$ zkušební. MSE je široce používaný ke kvantifikaci kvality obrazu, avšak pokud je používán samostatně nemá dostatečnou korelaci rozumné kvality, proto by se měl používat s dalšími metrikami, nebo vizuálním hodnocením [6].

RMSE³

Principiálně se jedná o druhou odmocninu střední kvadratické chyby, kterou lze vyjádřit jako [18]:

$$RMSE = \sqrt{MSE} \quad (17)$$

Popularita RMSE vyplývá převážně ze skutečnosti, že jde obecně o nejlepší aproximaci standardní chyby. [6]

GAE⁴

Jedná se o metodu posuzující kvalitu transformovaného obrazu používanou k nahrazení nebo doplnění RMSE metody. Je žádoucí pokud je každá hodnota pixelu mezi původním a transformo-

²Mean squared error - střední kvadratická chyba.

³Root mean squared error - střední kvadratická odchylka.

⁴Geometric average error - geometrická průměrová chyba.

vaným obrazem odlišná. Pokud se GAE blíží k nule je možno hovořit o velmi dobré transformaci charakteristickou malými rozdíly a to platí i opačně [30]. Matematicky lze popsat [6]:

$$GAE = (\Pi_{i=1}^M \Pi_{j=1}^N \sqrt{g_{i,j} - f_{i,j}})^{\frac{1}{MN}} \quad (18)$$

Kde $g_{i,j}$ značí originální obraz a $f_{i,j}$ zkušební [6].

SNR⁵

Porovnává úroveň požadovaného signálu s úrovní šumu na pozadí. Čím vyšší bude poměr, tím méně je rušivý šum, což odpovídá dobré kvalitě obrazu [31]. Matematicky vyjádřeno [6]

$$SNR = 10 \log_{10} \cdot \frac{\sum_{i=1}^M \sum_{j=1}^N (g_{i,j}^2 - f_{i,j}^2)}{\sum_{i=1}^M \sum_{j=1}^N (g_{i,j} - f_{i,j})^2} \quad (19)$$

Kde $g_{i,j}$ značí originální obraz a $f_{i,j}$ zkušební [6].

PSNR⁶

Jedná se o poměr maximálního možného výkonu signálu a výkonu zkreslení, přičemž bude vyšší pro lepší obraz a naopak. Měří, jak přesně se transformovaný obraz podobá původnímu [6, 27]. Lze vypočítat jako [27]:

$$PSNR = 10 \log \cdot \frac{D^2}{MSE} \quad (20)$$

Kde D označuje dynamický rozsah intenzity pixelů, například pro 8 bitový obrázek bude $D = 255$ [27].

Q index⁷

Tento index kvality měří jakékoliv zkreslení jako kombinaci tří různých faktorů:

- ztráty korelace
- zkreslení jasu
- zkreslení kontrastu

Tyto tři různé faktory definující Q index lze zapsat jako [32]:

$$Q = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \cdot \frac{2\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2} \quad (21)$$

⁵Signal to noise ratio - poměr signálu k šumu.

⁶Peak signal to noise ratio - špičkový poměr signálu k šumu.

⁷Quality index - univerzální index kvality.

Kde první složka rovnice značí korelační koeficient mezi x a y , které popisují originální a testovací obraz. Tento koeficient měří stupeň lineární korelace mezi těmito koeficienty a jejich dynamický rozsah $[-1, 1]$, přičemž nejlepší hodnota 1 se získá pokud $y_i = ax_i + b$ pro všechny $i = 1, 2, \dots, N$, a a b označuje konstanty, kdy $a > 0$. Druhá komponenta rovnice s hodnotovým rozsahem $[0, 1]$ měří, jak blízka je střední hodnota jasu mezi x a y . Ta je rovna 1 pouze pokud $\bar{x} = \bar{y}$. σ_x a σ_y lze považovat za odhad kontrastu x a y , neboli standardní odchylky. Třetí složka měří, jak moc jsou si podobné kontrasty obrázků, kde její rozsah hodnot je také $[0, 1]$, přičemž nejlepší hodnoty 1 je dosaženo pouze pokud $\sigma_x = \sigma_y$ [6, 32].

SSIM⁸

Tato metoda se snaží modelovat strukturální informace obrazu, která je založená na skutečnosti, že pixely přirozeného obrazu vykazují silné závislosti poskytující užitečné informace o jeho struktuře. Algoritmus SSIM definuje degradaci obrazu jako strukturální změnu. Provádí měření podobnosti ve třech krocích:

- Srovnání dle jasu
- Porovnání kontrastu
- Porovnání struktur obrazu

SSIM index může být definován podle vztahu [29]:

$$SSIM = \frac{(2\bar{y}\bar{x} + c_1) \cdot (2\sigma_{xy} + c_2)}{(\bar{y}^2 + \bar{x}^2 + c_1) \cdot (\sigma_y^2 + \sigma_x^2 + c_2)} \quad (22)$$

Přičemž

$$\begin{aligned} \bar{x} &= \frac{1}{L} \sum_{i=1}^L x_i, & \bar{y} &= \frac{1}{L} \sum_{i=1}^L y_i, \\ \sigma_x^2 &= \frac{1}{L-1} \sum_{i=1}^L (x_i - \bar{x})^2, & \sigma_y^2 &= \frac{1}{L-1} \sum_{i=1}^L (y_i - \bar{y})^2, \\ \sigma_{xy} &= \frac{1}{L-1} \sum_{i=1}^L (x_i - \bar{x}) \cdot (y_i - \bar{y}) \end{aligned} \quad (23)$$

Kde x , y a L reprezentují originální obraz, testovaný obraz a počet pixelů v části zpracovaného obrazu. c_1 a c_2 jsou hodnoty konstant použité pro výpočet metriky SSIM za účelem stabilizace. σ_x σ_y jsou rozptyly ze vzorku signálu x a y , přičemž σ_{xy} míní vzájemné vazby mezi x a y . Dynamický rozsah SSIM leží v rozsahu hodnot $[-1, 1]$, přičemž nejlepší hodnota 1 může být dosažena pouze pokud $y = x$ [27, 29].

⁸Structural similarity index - strukturální index podobnosti.

Pearsonův korelační koeficient

Jednoduše se označuje jako korelace nebo korelační koeficient. Jedná se o parametr, který měří lineární závislost mezi dvěma proměnnými. Jedná se o bezrozměrnou veličinu, která je v intervalu 0 až 1, přičemž 1 představuje úplnou podobnost [33].

2.4.3 Hodnocení kvality obrazu v ultrazvukovém zobrazování

Kvalita ultrazvukového obrazu je závislá na **axiálním** a **laterálním** rozlišení obrazu. Rozlišení je definováno jako nejmenší vzdálenost mezi dvěma body, které mohou být interpretovány jako vzájemně odlišné. I přestože jsou x a y lineární, mohou se mezi nimi vyskytnout relativní deformace, které jsou hodnoceny v druhé a třetí složce.

Axiální rozlišení, neboli podélné rozlišení, je definováno jako nejmenší vzdálenost mezi dvěma odlišnými body, které leží ve směru šíření ultrazvuku. Závisí na vlnové délce ultrazvukového paprsku, neboli na frekvenci, přičemž s rostoucí frekvencí se rozlišovací schopnost zvyšuje.

Laterální rozlišení, neboli příčné rozlišení, popisuje schopnost reprezentovat dva odlišné body, které leží v pravém úhlu ke směru šíření ultrazvuku. To závisí na šířce ultrazvukového paprsku pro který platí, že čím je paprsek užší, tím je rozlišovací schopnost přesnější [6].

3 Metody pro eliminaci šumu z ultrazvukových obrazů

Šum obrazu je náhodná odchylka jasu nebo barevných informací v obrazech vytvořených snímačem, obvody skeneru nebo digitální kamery. V digitálních lékařských obrazech je způsoben přenosovými médii, šumem z přenosových médiích a orgány, jako je tělesný tuk a dýchací pohyb, které zhoršují kvalitu obrazu, a tím komplikují pozorování vyšetřované oblasti. Obrazový šum lze považovat za nežádoucí vedlejší produkt zachycení obrazu. Vlastnosti šumu závisí na jeho zdroji, zároveň tak jako i použitý filtr nebo operátor redukce šumu. Algoritmy redukce se používají k odstranění šumu bez ztráty velkého množství detailů obsažených v obraze [18, 19].

3.1 Jednotlivé typy šumu

Šum, který se vyskytuje v ultrazvukových snímcích lze klasifikovat jako:


- **Aditivní:** Gaussovský šum
- **impulsní:** Salt and Pepper
- **multiplikativní:** speckle

3.1.1 Gaussovský šum

Jedná se o pravděpodobně nejčastější aditivní šum. Gaussovský šum je statistický a jeho hustota pravděpodobnosti se vyznačuje normální distribucí, také známou jako Gaussova distribuce [19, 22]. Obecně narušuje hodnoty stupnice šedi v digitálních snímcích. Gaussův šum je způsoben přírodními zdroji, jako je tepelná vibrace atomů a diskrétní povaha radiace tepelných objektů [34]. Jeho funkce rozdělení pravděpodobnosti lze popsat takto [18]:

$$P(z) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(z-m)^2}{2\sigma^2}} \quad (24)$$

Jak si je možno povšimnout (viz rov. 3), z reprezentuje stupnici šedi, m střední hodnotu funkce a σ představuje směrodatnou odchylku šumu. Grafické znázornění (viz obr. 10) [18].



Obrázek 10: Funkce hustoty pravděpodobnosti Gaussova šumu [18]

Na obr. 10 lze sledovat závislost mezi hodnotami stupni šedi z a pravděpodobností jejího výskytu $P_{(z)}$ [14].

3.1.2 Salt and Pepper šum

Tento typ šumu odkazuje na širokou škálu procesů, které mají za následek stejnou základní degradaci obrazu. Lze jej také označit jako hroty intenzity, které mohou nabývat hodnot 0 nebo 1. Pixely, které jsou poškozeny tímto typem šumu jsou alternativně nastaveny na maximální nebo minimální hodnotu, což pro 8 bitový přenos činí 255 nebo 0, a tím tvoří strukturu podobnou soli a pepře. Obraz obsahující tento typ šumu bude mít tmavé pixely ve světlých oblastech a světlé pixely v tmavých. Zapříčiněn je náhlými změnami obrazového signálu, chybou přenosu dat nebo chybou analogově digitálního převodníku [18, 19, 34]. Rozdělení pravděpodobnostní funkce je dána [18]:

$$P_{(z)} = \begin{cases} P_a & \text{for } z = a \\ P_b & \text{for } z = b \\ 0 & \text{v opačném případě} \end{cases} \quad (25)$$

Kde na rovnici (viz rov. 25) z představuje úroveň šedi, pokud $b > a$ šedá hladina b se v obraze objeví jako světlá tečka a naopak úroveň a bude vypadat jako tmavá [18].

254	207	210		254	207	210
97	212	32	→	97	0	32
62	106	20		62	106	20

Obrázek 11: Poškození centrálního pixelu šumem Salt and Pepper [34]

Na obr 11 je uvažováno o 3×3 obrazové matici, kde je předpoklad, že centrální hodnota matic je poškozená šumem Salt and Pepper, proto je střední hodnota 212 nahrazena 0 [34].

3.1.3 Speckle

Šum a artefakty mohou způsobit degradaci signálu a obrazu v mnoha medicínských zobrazovacích modalitách, kdy tato degradace může mít významný dopad na kvalitu obrazu a tedy vliv na lidskou interpretaci či přesnost počítačem podporovaných metod. Špatná kvalita obrazu často činí problematiku rozpoznávání a kvantitativního měření značně problematickou a nespolehlivou. Speckle šum patří mezi zásadní omezující faktory při zpracování ultrazvukového obrazu, které jsou reprezentovány světlými a tmavými body [6].

V ultrazvukových snímcích je speckle typický zrnitým charakterem. S kterým je možno zacházet jako se šumem a hledat možnosti jak ho potlačit, nebo ho lze považovat ze signál charakterizující strukturu, do které patří. [35].

Aby bylo možné odvodit účinný despecklový filtr, je zapotřebí uvést matematický model, který může být aproximován jako multiplikativní a je dán vztahem [31]:

$$f_{ij} = g_{ij}u_{ij} + a_{ij} \quad (26)$$

kde f_{ij} představuje pixel s nejvyšší intenzitou, g_{ij} reprezentují pixely neobsahující žádný šum, u_{ij} a a_{ij} reprezentují multiplikativní a aditivní šum. Indexy i, j vyznačují prostorové polohy, které spadají do 2D prostoru reálných čísel.

Despeckling je založen na odhadu skutečné intenzity g_{ij} jako funkce intenzity pixelu f_{ij} a lokální statistiky vypočítané sousedských pixelů [6, 31].

Vzhledem k tomu, že účinek přídavného šumu je výrazně menší než účinek násobícího (viz 26), můžeme zapsat jako [31]:

$$f_{ij} \approx g_{ij}u_{ij} \quad (27)$$

Logaritmická komprese transformuje model (viz 27) do klasického signálu ve formě přídavného šumu jako [31]:

$$\log f_{ij} = \log g_{ij} + \log u_{ij} \quad (28)$$

a

$$x_{ij} = y_{ij} + n_{ij} \quad (29)$$

kde x_i je definováno jako ultrazvukový obraz po logaritmické kompresi $\log f_{ij}$ a y_i, n_i reprezentují pixely neobsahující šum a šumový komponent po logaritmické kompresi $\log g_{ij}, \log u_{ij}$ [6, 31].

Rozdělení pravděpodobnostní funkce je dána [18]:

$$P(z) = \frac{z^{\alpha-1}}{(\alpha-1)! \cdot a^\alpha} \cdot e^{-\frac{z}{a}} \quad (30)$$

kde z reprezentuje škálu šedi a a^α odchylku [18].

3.2 Pokročilé metody filtrace

V této podkapitole bude pojednáváno o pokročilých metodách filtrace. Částečně bude navázáno na 2.3. Vytvořená řešení poslouží jako teoretický podklad k praktické části.

3.2.1 Adaptivní filtrace v prostorové doméně

Princip filtrace v prostorové doméně byl popsán v kapitole 2.3.1. V článku od Kaur a Singh z roku 2014 [36] jsou adaptivní filtry schopny redukce šumu nestacionárních⁹ obrazů. Jsou známé především možností automatického rozlišování neznámých faktorů nebo při zpracování variabilního signálu s malou apriorní znalostí. Dle Coupé a kol. z roku 2009 [37] je adaptivní filtrace široce používaná v obnově ultrazvukových snímků, jelikož je snadno implementovatelná. Mezi běžné adaptivní filtry se zde řadí:

- Lee filtr
- Frost filter
- Kuan filter

Lee filtr¹⁰

V článku od Stella a Trivedi z roku 2013 [39] se jedná o adaptivní filtr, který mění své vlastnosti v závislosti na lokálních statistikách sousedních obrazových bodů konkrétního pixelu. Je schopen vyhlazovat šum v plochých oblastech a zároveň ponechává beze změn jemné detaily linií a textur. Lee filtr byl navržen pro eliminaci speckle šumu při současném zachování okrajů a bodových prvků v radarovém obraze. Používá především malé okno, přičemž se v každém pohybu odhadují místní průměry a odchylky. V oblastech s nízkou úrovní signálu, tzv. ploché oblasti se hodnota odhadovaného pixelu blíží k místnímu průměru, zatímco v místech s vysokou úrovní signálu tzv. okrajové oblasti se hodnota odhadovaného pixelu ponechává. Toto má za následek zanechávání šumu v blízkosti okrajů a linií. Matematicky lze vyjádřit jako [40]:

$$W(x, y) = 1 - \frac{C_B^2}{C_I^2 + C_B^2} \quad (31)$$

Kde C_I je variační koeficient zašuměného obrazu a C_B je variační koeficient šumu. $W(x, y)$ značí adaptivní filtrační koeficient, který se obecně blíží k nule v rovnoměrných oblastech, což vede k malým změnám hodnot pixelů v blízkosti hran [40].

Frost filtr¹¹

Studie od Sivakumar a kol. z roku 2010 [40] popisuje Frost filtr jako adaptivní exponenciálně vážený průměrovací filtr založený na variačním koeficientu¹². Nahrazuje zájmový pixel váženým součtem hodnot v pohybující se masce, kde se váhové faktory zvětšují se zvyšujícím se rozptylem v rámci masky. V této studii se testovalo v prostředí Matlab více než 200 digitálních

⁹Obrazy, které mají náhle změny intenzity [36].

¹⁰Lee filtr představil Jong-Sen Lee ve studii z roku 1980 [38].

¹¹Frostův filtr byl poprvé představen Victorem S. Frostem a kol. v článku z roku 1982 [41].

¹²poměr hodnot lokální směrodatné odchylky k místnímu průměru degradovaného obrazu [40].

ultrazvukových snímků ledvin, břicha a jater pomocí přístroje¹³, který pracoval v B-Módu. Došli k závěru, že Frost filtr mírně zlepšuje informaci hran v obrazu. Filtr předpokládá speckle jako multiplikační stacionární šum, který lze matematicky popsat jako [31]:

$$y_{i,j} = \sum_{n \cdot n} k\alpha \cdot \exp(-\alpha|t|)x_{i+n,j+n} \quad (32)$$

$n \cdot n$ značí hodnoty pohybující se masky, $t = \sqrt{i^2 + j^2}$ je vzdálenost mezi aktuálním pixelem (n, n) a zpracovaným obrazovým bodem $(n + i, n + j)$, α vyjadřuje adaptivní koeficient určený lokálními statistikami v pohybujícím se okně a k je normalizační konstanta. Je zřejmé, že pokud bude hodnota α malá, bude filtr fungovat jako průměrovací filtr, naopak bude-li velká, tak bude mít tendenci zachovat původní pozorovaný obraz [31].

Kuan filtr¹⁴

Podle Vanithamani a kol. z roku 2010 [31], funguje Kuan filtr na obdobném principu jako Lee filtr viz 3.2.1, akorát s odlišnou váhovou funkcí danou vztahem [40]:

$$W(x, y) = \frac{1 - \frac{C_B^2}{C_I^2}}{1 + C_B^2} \quad (33)$$

Kde C_I je variační koeficient zašuměného obrazu a C_B je variační koeficient šumu. $W(x, y)$ značí adaptivní filtrační koeficient, který se obecně blíží k nule v rovnoměrných oblastech, což vede k malým změnám hodnot pixelů v blízkosti hran [40].

3.2.2 Anizotropní difuze

Anizotropní difuze, dle Stella a Trivedi z roku 2013 [39], se obvykle používá při filtraci v prostorové doméně. Anizotropní difuzní filtry obvykle používají strategie prostorové regulace, které jsou reprezentovány dvěma zástupci označeny jako **anizotropní difuze zlepšující hrany** v obraze a **anizotropní difuze zvyšující koherenci**. Užití anizotropní difuze zlepšující hrany v obraze je výhodná především pro zašuměné obrazy, zatímco anizotropní difuze zvyšující koherenci je dobře přizpůsobena pro zpracování jednodimenzionálních signálů. Anizotropní difuze vyhlazuje homogenní oblasti obrazu a zároveň zachovává hrany.

Studie od Sivakumar a kol. z roku 2010 [40] uvádí, že difuzní filtry mohou být přímo aplikovány na snímky za cílem odstranění speckle šumu řešením parciálních diferenciálních rovnic. Anizotropní difuze vylepšuje kontrast obrazu a redukuje šum bez požadavků na znalost výkonového spektra. V práci od Sivakumar a kol. byly zkoušeny dva difuzní filtry:

- Speckle redukující anizotropní difuze (SRAD)

¹³GE healthcare model VIVID7 [40].

¹⁴Představil Darwin T. Kuan a kol. ve studii z roku 1985 [42].

- Perona a Malik anizotropní difuzní filtr (PMAD¹⁵)

Podle článku metoda SRAD eliminuje speckle bez narušení užitečných obrazových informací a důležitých hran obrazu, pomocí okamžité variace koeficientu při redukci speckle. Zatímco PMAD je založená na nelineární parciální diferenciální rovnici.

V této studii byly použity stejné podmínky uvedené u Frost filtru, přičemž došli k závěru, že metoda SRAD potlačuje speckle šum a zároveň zvyšuje PSNR¹⁶. Při iteracích větších než 8 dochází k rozmazání obrazu. Pokud je iterace nižší než 4 nenachází znatelný rozdíl oproti ostatním filtrům, proto došli k závěru, že optimální hodnota iterace pro redukci speckle je v rozmezí 4 až 8.

Filtr PMAD v B-módu namísto eliminace speckle šumu jej zlepšuje. Na základě parametru PSNR je zřetelné, že PMAD není účinným filtrem pro ultrazvukové snímky. Také parametry Q index¹⁷ a SSIM¹⁸ se značně snižují se zvyšující hodnotou iterace, což svědčí o zkreslení obrazu.

3.2.3 Metody založené na vlnkové doméně

Vlnky jsou prosté matematické funkce, které slouží k analýze dat pomocí měřítka nebo rozlišení, využívající se při studiích signálu. Vlnkova doména spadá pod nelineární adaptivní transformaci. Hlavním rozdílem od ostatních transformací je schopnost rozdělení signálu na jeho komponenty kmitočtů, a zároveň možnost změřit rozsah, ve kterém jsou frekvence analyzovány. Operátory filtrace ve vlnkové doméně jsou vyjimečně vhodné pro kompresi dat, redukci šumu či detekci singularity signálu. Filtrační operace mohou být rozděleny na lineární a nelineární metody, kde podrobná klasifikace je uvedena na obrázku 12 [18]:

Lineární filtrace, kde patří Wienerův filtr ve vlnkové doméně, poskytuje optimální výsledky pokud je šum v signálu modelován jako Gaussův proces, přičemž kritérium přesnosti je založeno na parametru (MSE¹⁹). Výsledkem je často filtrovaný obraz, který je vizuálně horší než původní zašuměný, i když operace úspěšně snižuje hodnotu MSE.

Nelineární filtrace spadá do nejvíce zkoumané oblasti filtrace šumu pomocí vlnkové transformace, založené na nelineárním koeficientu prahování. Využívá vlastností vlnkové transformace, tím že se signál při menším počtu koeficientů stává koncentrovanějším, zatímco šum ne, a proto je takto možné oddělit signál od šumu [18].

Wienerův filtr

Podle článku od Stella a Trivedi z roku 2013 [39], jsou 2 metody implementace Wienerovi filtrace. Metoda v prostorové doméně založená na střední kvadratické chybě popsána v 2.3.1. Princip založený na filtraci pomocí transformace využívá Fourierovy transformační metody, avšak

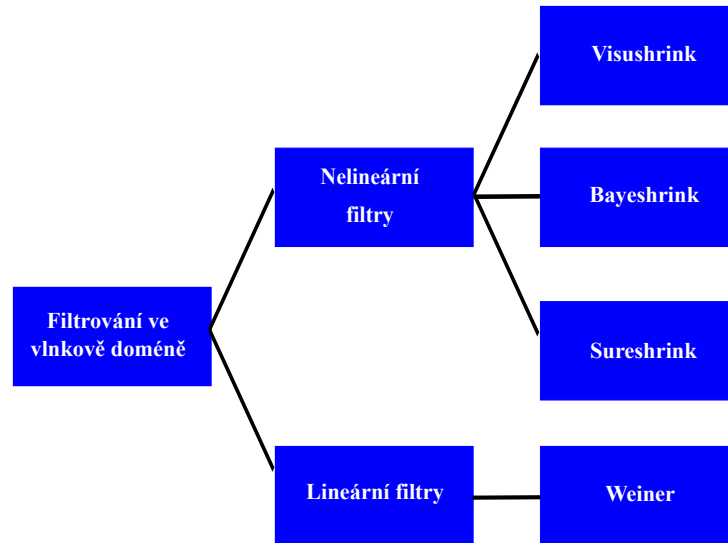
¹⁵představil P. Perona a J. Malik ve studii z roku 1990 [43].

¹⁶Peak signal to noise ratio - špičkový poměr signálu k šumu.

¹⁷Quality index - univerzální index kvality.

¹⁸Structural similarity index - strukturální index podobnosti.

¹⁹Mean squared error - střední kvadratická chyba.



Obrázek 12: Klasifikace filtrů ve vlnkové doméně [18].

vyžaduje alespoň základní znalosti výkonových spekter šumu a původního obrazu. Filtr je založen na globálních a místních statistikách. Ve studii pracovali v prostředí MATLAB R2009 kde testovali různé šířky oken ($3 \cdot 3$, $5 \cdot 5$, $7 \cdot 7$) na digitálních snímcích zašuměných speckle šumem. Došli k závěru, že Wienerův filtr s maskou $3 \cdot 3$ dosahuje nejnížší RMSE²⁰ a nejvyšší hodnoty PSNR²¹. Hodnota Q indexu²² byla pro digitální obraz téměř rovna 1, což zajišťuje dobré subjektivní hodnocení obrazu.

Wienerův filtr byl také testován ve studii Sivakumar a Nedumaran z roku 2010 [44], kde testovali více než 200 ultrazvukových snímků v B-módu. Došli k výsledkům, že Wienerovi filtrační techniky fungovaly lépe než ostatní standardní speckle filtry. Hodnotící parametry kvality RMSE dosahovali nízkých hodnot, zatímco hodnota PSNR vysokých, což svědčí o lepším výsledku filtrace.

VisuShrink²³

Studie od Singh a Jain z roku 2013 [18] popisuje VisuShrink jako nelineární vlnkový filter, kde prahová hodnota t je odvozena ze standardní odchylky šumu. Používá se tvrdého prahování tzv. univerzální práh, který je definován jako [18]:

$$t = \sigma \sqrt{2 \log n} \quad (34)$$

Kde σ představuje rozptyl šumu přítomný v signálu a n definuje velikost signálu nebo počet vzorků. Podlé této studie, je hlavním nedostatkem, že se nejedná o minimalizaci střední kva-

²⁰Root mean squared error - střední kvadratická odchylka.

²¹Peak signal to noise ratio - špičkový poměr signálu k šumu.

²²Quality index - univerzální index kvality.

²³Představil David L. Donoho a Iain M. Johnstone ve studii z roku 1994 [45].

dratické chyby. Filtrované obrázky jsou příliš vyhlazené, to je způsobeno odstraněním mnoha koeficientů obrazu. Další podstatnou nevýhodou je, že se může aplikovat pouze na aditivní šum.

SureShrink²⁴

Dle Rai a kol. z roku 2012 [46] se jedná o metodu adaptivního prahování, při níž jsou vlnkové koeficienty zpracovávány jednotlivě. Pokud se v jednotlivých úrovních vlnek nachází úroveň, která není řídká, dochází k použití prahu, který minimalizuje Steinův nezkreslený odhad rizika (Sure²⁵). Metoda SureShrink se používá k potlačení aditivního šumu ve vlnkové doméně, kde je použita prahová hodnota (T Sure), definovaná jako [18]:

$$T_{sure} = \min(t, \sigma\sqrt{2\log n}) \quad (35)$$

Kde t demonstruje hodnotu Steinova nezkresleného odhadu rizika, σ vypočtený rozptyl šumu a n popisuje velikost obrázku [18].

BayesShrink²⁶

Článek od Gupta a Garg z roku 2015 [49] uvádí kritérium prahování odhadovacího limitu nazvaného BayesShrink, který předpokládá generalizovanou Gaussovu distribuci pro vlnkové koeficienty v každém detailu dílčího pásma. Používá se tzv. Bayesovský matematický rámec pro nalezení nejlepšího prahu, který minimalizuje Bayesovské riziko vyjádřené jako [49]:

$$\sigma_B = \frac{\lambda_{noise}^2}{\lambda_{signal}} = \frac{\lambda_{noise}^2}{\sqrt{\max(\lambda_G^2 - \lambda_{noise}^2, 0)}} \quad (36)$$

Kde $\lambda_G^2 = \frac{1}{P_s} \sum_{x,y=1}^{N_s} V_{xy}^2$ a P_s je počet vlnkových koeficientů V_{xy} ve zvažovaném pásmu. Robustní odhad rozptylu šumu využívá střední absolutní hodnotu vlnkových koeficientů, která je citlivá na izolované odlehlé hodnoty potencionálně vysokou amplitudou definovanou jako [49]:

$$\lambda_{noise} = \frac{\text{median}(|V_{xy}|)}{0.6745}, V_{xy} \in \text{subpásmo } HH \quad (37)$$

V_{xy} označuje koeficienty vlnky HH, které tvoří nejjemnější úroveň rozkladu [49].

Tato studie testovala na metodu jak pro standardní obrázek, tak pro ultrazvukový snímek. Všechny obrázky byly uměle poškozeny Gaussovým šumem o různých odchylkách. Jako objektivní parametry pro posouzení kvality metod zvolily PSNR a SSIM, kde ze získaných výsledků lze usuzovat, že metoda je docela efektivní a vede ke zlepšení parametrů PSNR a SSIM.

²⁴Představil David L. Donoho a Iain M. Johnstone ve studii z roku 1994 [45].

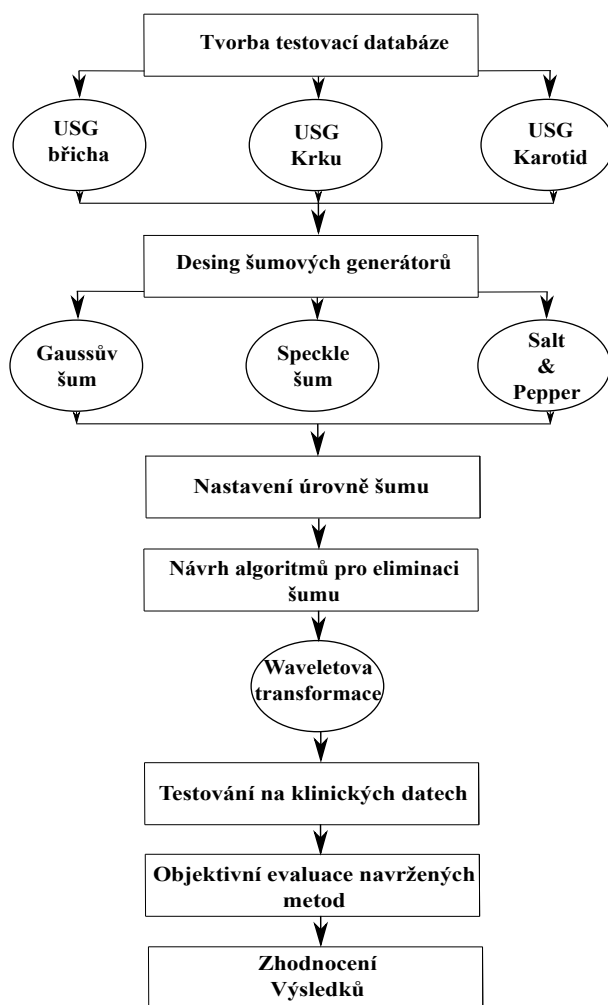
²⁵Podle studie od Donoho a Johnstone z roku 1995 [47], poskytuje údaj o přesnosti daného odhadu. To je důležité, jelikož parametr střední kvadratické chyby je funkcí neznámé odhadované hodnoty, kterou nelze přesně určit.

²⁶Navrhnul Chang, Yu a Vetterli ve studii z roku 2000 [48].

Studie od Karthikeyan a Chandrasekar z roku 2011 [50] navrhla nový hybridní model pro filtraci speckle šumu, která je kombinací Anisotropní difúze, SRAD filtru a BayesShrink prahování. Experimentální výsledky dokazují, že navrhovaný model vytváří obrazy, které jsou čistší a hladší při současném udržení významných detailů obrazu, což má za následek jasnější a atraktivnější výsledný obraz. Kromě toho je navrhovaná metoda rychlá pro dosažení konvergence, což má přímý dopad na snížení šumu.

4 Implementace algoritmu eliminace šumu z ultrazvukových dat

Po nastudování problematiky výskytu šumů v ultrazvukových obrazech a její následné filtrace jsem rozhodl, že cíl práce bude zaměřen na navrhnutí a testování vlnkové transformace pro filtraci variantních typů šumu. Vlnková transformace bude testována na široké databázi obsahující klinické ultrazvukové obrazy. Hlavním záměrem studie bude vliv dynamiky šumu na efektivitu filtrace kooperativních vlněk. Z teoretického úvodu je totiž zřejmé, že filtrace šumu v ultrazvukových obrazech je poměrně častá a žádoucí. Postupně v této kapitole budou popsány technické parametry používaného ultrazvukového přístroje, návrh testovací databáze ultrazvukových klinických obrazů a design jednotlivých šumových generátorů, které se využijí pro testování filtrace. Závěr kapitoly bude zaměřen na vlnkovou transformaci a její aplikování pro filtraci klinických ultrazvukových obrazů.



Obrázek 13: Návrh řešení praktické části.

Vývojový diagram znázorněný na obr. 13 popisuje návrh řešení praktické části. Jednotlivé kroky budou popsány níže.

4.1 Technické parametry ultrazvukového přístroje

K vytvoření testovací databáze byl použit ultrazvukový přístroj od firmy GE LOGIQ P6 Pro, který je znázorněn na obr. 14. Tento ultrazvukový přístroj disponuje aplikacemi pro široké spektrum vyšetření například abdominální, muskuloskeletální, gynekologická, urologická a mnoha dalších. Dokáže pracovat o mnoha vyšetřovacích módech, mezi které patří B-mód, M-mód, 3D a 4D metody, Dopplerovské techniky a mnoho jiných.



Obrázek 14: Ultrazvukový přístroj GE LOGIQ P6 PRO [51].


Na obrázku je možné vidět části přístroje jako 17-ti palcový monitor, klávesnice široká 43 cm a potřebné vyšetřovací sondy, které se rozdělují na **konvexní**, **sektorové** a **lineární**. Sektorové sondy se používají především v kardiologii a pracují o frekvenci 2 až 3 MHz. Sondy konvexní pracující o kmitočtu 2 až 10 MHz se využívají zejména pro vyšetření dutiny břišní a lineární sondy slouží pro vyšetřování povrchově uložených orgánů, které pracují o frekvenci 3 až 15 MHz [51].

4.2 Tvorba testovací databáze ultrazvukových klinických obrazů

Pomocí přístroje popsaného výše je k testování vybraných algoritmů pro filtraci šumu vytvořena databáze ultrazvukových snímků *data*, která obsahuje 220 ultrazvukových klinických obrazů. Ultrazvukové obrazy jsou rozděleny do třech kategorií, pojmenovaných dle místa vyšetření lidského těla:

- Databáze břicho obsahuje 100 ultrazvukových snímků z vyšetření břicha. K akvizici dat se nejčastěji používá konvexní sonda [10].
- Databáze krk obsahuje 40 snímků z ultrazvukového vyšetření krku. Pro vyšetření se používá sonda lineární [10].
- Poslední kategorie, databáze karotidy, obsahuje 80 ultrazvukových dat karotid. K akvizici se využívá lineární sonda [10].

Ukázka vytvořených snímků k testování je znázorněna na obr. 15. Z klinického hlediska se jedná o snímky fyziologické i patologické. Data jsou zcela anonymizována. Veškeré snímky jsou nahrané v B-módu, který byl popsán v podkapitole 1.1.2. Data jsou uložena ve formátu .jpg a byly pořízeny na klinickém pracovišti přístrojem Ge LOGIQ P6 Pro viz 4.1. Tato data poskytují vynikající podklad pro následné testování a hodnocení kvality obrazové filtrace.



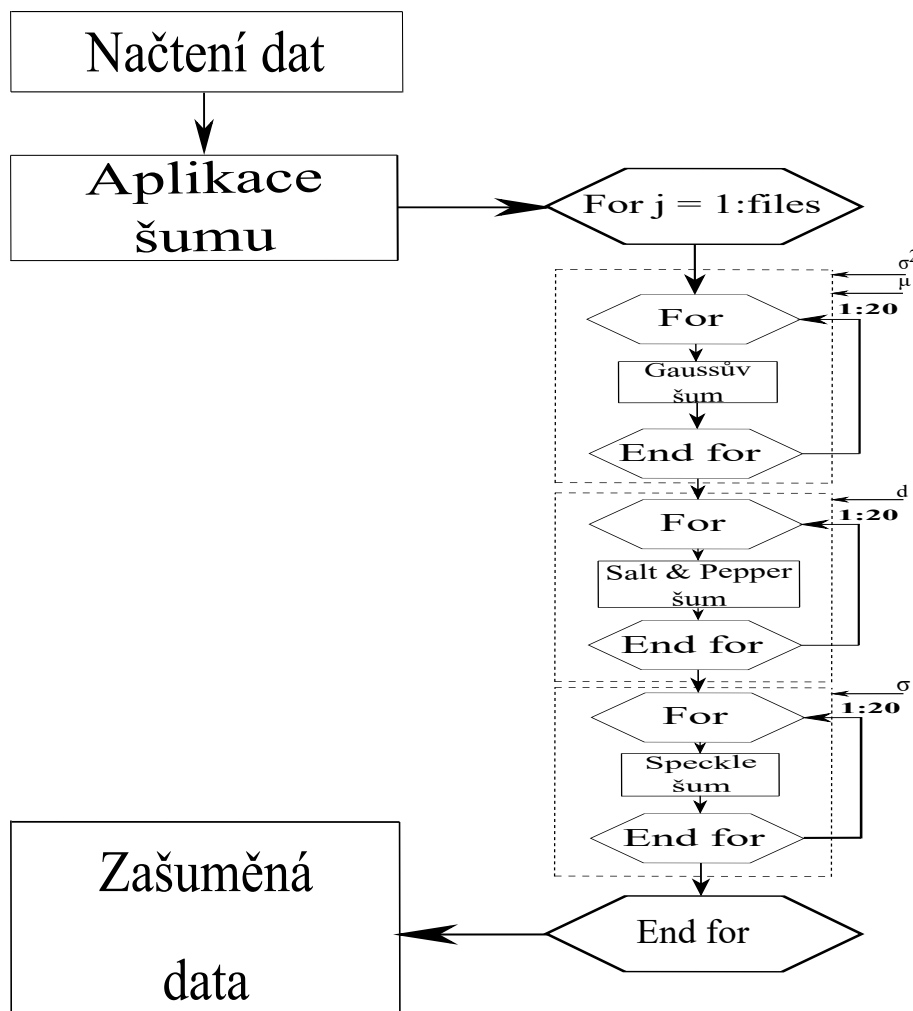
Obrázek 15: Ukázka vytvořené klinické databáze.

4.2.1 Zpracování vytvořené databáze

Klinická databáze je následně zpracována v prostředí Matlab. Jednotlivé ultrazvukové snímky byly načteny do buňky pro následné přehledné zpracování. V prvním kroku se veškerá nativní data převedla do škály šedi pomocí funkce *rgb2gray*. Vestavěná Funkce převádí obrazy na stupně šedi odstraněním informací o odstínu a sytosti, při zachování jasů. Jednotlivé snímky jsou ukládány v řádcích a následně zpracovány ve sloupcích.

4.3 Aplikace šumových generátorů pro ultrazvukové obrazy

Data jsou uměle zašuměna v prostředí Matlab funkcí *imnoise*. K zašumění jsou použity tři typy variantních šumů, které jsou nastaveny o odlišných parametrech. Šumy byly zvoleny na základě jejich pravděpodobnosti výskytu v ultrazvukových obrazech a pro srovnání účinnosti metod filtrace. Byl vybrán aditivní Gaussovský šum, impulsní šum typu Salt and Pepper a multiplikativní Speckle šum. Šumy byly popsány v kapitole 3.




Obrázek 16: Vývojový diagram znázorňující aplikaci variantních typů šumu.

V prvním kroku jsou načtena data z jednotlivých vytvořených databází. Poté se aplikují šumivé generátory na všechna data. Je aplikováno 20 rozdílných úrovní o rozdílných parametrech. Výstupem jsou uměle zašuměná data vhodná k objektivnímu testování filtrace.


Výpočetní náročnost implementace šumu pro databázi břicho činila 51.3s. U databáze krk 23.1s a databáze karotidy 35.1s.

4.3.1 Gaussovský šum

Gaussovský šum je nastaven s konstantní hodnotou rozptylu σ^2 0.01 a střední hodnotou o dvaceti rozdílných úrovních μ 0.01, 0.02, 0.03, ..., 0.20.



Obrázek 17: Ukázka zašuměných klinických snímků z databáze břicho Gaussovým šumem.



Obrázek 18: Ukázka zašuměných klinických snímků z databáze karotidy Gaussovým šumem.

Na obrázku 17, 18, 19 je ukázka zašumění jednotlivých databází ultrazvukových klinických dat Gaussovým šumem. Obrázek 17 znázorňuje ukázku databáze břicho. Obrázek 18 zobrazuje ukázku databáze karotidy a obrázek 19 vyobrazuje ukázku databáze krk. Snímek (a) líčí originální nezašuměný snímek, (b) znázorňuje stejný snímek zašuměný Gaussovým šumem o rozptylu σ^2 0.01 a střední hodnotě μ 0.1. Na snímku (c) lze pozorovat aplikovaný šum o rozptylu σ^2 0.01 a střední hodnotě μ 0.2.



(a) Originální snímek UZ krku


(b) $\sigma^2 = 0.01$, $\mu = 0.1$

(c) $\sigma^2 = 0.01$, $\mu = 0.2$

Obrázek 19: Ukázka zašuměných klinických snímků z databáze krk Gaussovým šumem.

4.3.2 Salt and Pepper šum

Šum typu Sůl a pepř je nastaven parametrem hustoty šumu d na úroveň o dvaceti rozdílných hodnotách 0.001, 0.002, 0.003, ..., 0.02.




(a) Originální snímek UZ břicha

(b) $d = 0.01$

(c) $d = 0.02$

Obrázek 20: Ukázka zašuměných klinických snímků z databáze břicho šumem typu Salt and Pepper.




(a) Originální snímek UZ karotid

(b) $d = 0.01$

(c) $d = 0.02$

Obrázek 21: Ukázka zašuměných klinických snímků z databáze karotidy šumem typu Salt and Pepper.



Obrázek 22: Ukázka zašuměných klinických snímků z databáze krk šumem typu Salt and Pepper.


Na obrázku 20, 21, 22 je ukázka zašumění jednotlivých databází ultrazvukových klinických dat šumem typu Sůl a Pepř. Obrázek 20 znázorňuje ukázkou databáze břicho. Obrázek 21 zobrazuje ukázkou databáze karotidy a obrázek 22 vyobrazuje ukázkou databáze krk. Snímek (a) líčí originální nezašuměný snímek, (b) znázorňuje stejný snímek zašuměný Salt and Pepper šumu o hustotě d 0.01. Na snímku (c) je možno pozorovat zašuměný snímek o hustotě d 0.02.

4.3.3 Speckle šum


Násobící speckle šum je v Matlabu generován pomocí vztahu:

$$J = I + n \cdot I \quad (38)$$


Kde I nám popisuje vstupní obraz, n rovnoměrně rozložený náhodný šum se střední hodnotou 0 a odchylkou σ , která byla nastavena o dvaceti rozdílných hodnotách 0.1, 0.2, 0.3, \dots , 2. J nám označuje výstupní obraz.



Obrázek 23: Ukázka zašuměných klinických snímků z databáze břicho šumem typu Speckle.



Obrázek 24: Ukázka zašuměných klinických snímků z databáze karotidy šumem typu Speckle.



Obrázek 25: Ukázka zašuměných klinických snímků z databáze krk šumem typu Speckle.

Na obrázku 23, 24, 25 je ukázka zašumění jednotlivých databází ultrazvukových klinických dat šumem typu speckle. Lze si povšimnout typického zrnitého charakteru Speckle šumu v ultrazvukových snímcích, který výrazně snižuje získání požadované diagnostické informace z obrazu. Takto zašuměný obraz by mohl vést k chybné interpretaci a následnému přehlédnutí významné patologie tkáně. Obrázek 23 znázorňuje ukázkou databáze břicho. Obrázek 24 zobrazuje ukázkou databáze karotidy a obrázek 25 vyobrazuje ukázkou databáze krk. Snímek (a) líčí originální nezašuměný snímek, (b) znázorňuje stejný snímek zašuměný speckle šumu o rozptylu $\sigma^2 = 1$. Na snímku (c) lze vidět aplikovaný šum nastavený o rozptylu $\sigma^2 = 2$.

Výše vyobrazená zašuměná data jsou ideální pro testování efektivity filtrace pomocí vlnkové transformace. Zejména pro šum typu speckle, který je charakteristický svým zrnitým charakterem vyskytovaný především v ultrazvukových obrazech. Klinická databáze poslouží pro porovnání efektivity filtrace v dílčích vyšetřovaných oblastech.

4.4 Vlnková transformace


Vlnky jsou matematické funkce, které analyzují data podle měřítka nebo rozlišení. Ty mohou pomoci při studiu signálu v odlišných oknech nebo v různých rozlišeních. Pokud je například signál zobrazen ve velkém okně, lze si všimnout hrubých funkcí, ale pokud je zobrazen v malém okně, lze zaznamenat pouze malé funkce. Vlnky poskytují některé výhody oproti Fourierovým transformacím. Například dobře pracují při aproximaci signálů s ostrými hroty nebo signály, které jsou nespojité. Vlnky mohou také modelovat nestacionární stochastické signály nebo je lze použít v aplikacích, jako je filtrace a komprese obrazu a mnoho dalších [52].

Vlnky rozdělují data na různé frekvenční komponenty, u kterých je poté možno zkoumat každou komponentu s rozlišením přizpůsobeným jejímu měřítku. Jinými slovy analyzuje obsah frekvencí obrazu v měřítku, které udávají množinu koeficientů odpovídajících různým stupnicím a různým směrům kmitočtu. Postup vlnkové analýzy označuje soubor ortonormálních bázevých funkcí generovaných dilatací a translací škálovací funkce φ (otecovské vlnky) a ψ (mateřské vlny) definující tvar vlnky. Jejich transformací vznikají dceřinné vlnky. Tento algoritmus v podstatě provádí dekompozici signálu dle zvoleného typu a šířky mateřské vlnky ψ . Mezi základní typy vlnek patří například: Haar, Daubechies, Symlets, Mexican hat a mnoho dalších [35, 53].

Vlnková transformace patří k tzv. víceměřítkovým transformacím, která se primárně dělí na kontinuální vlnkovou transformaci (CWT) a diskrétní vlnkovou transformaci (DWT) [54, 55]. Níže jsou uvedeny ukázky jednotlivých typů vlnek. V této práci byly voleny typy vlnek rodiny Daubechies a Symlets.

Haar vlnka


Jedná se o první a nejjednodušší typ vlnky, která je nesouvislá a připomíná funkci kroku. Představuje stejnou vlnku jako Daubechies db1, která neumožňuje hladkou rekonstrukci signálu [56].



Obrázek 26: Haar vlnka [56].

Vlnka typu Daubechies


Pojmenovaná podle Ingrid Daubechies, která vynalezla tzv. kompaktně podporované orto-normální vlnky, díky nim je možné provádět diskrétní vlnkovou transformaci. Rodina vlněk Daubechies je popsána dbN , kde N označuje pořadí a db příjmení vlnky. Vlnka $db1$ je totažná s vlnkou Haar viz obr. 26. Níže jsou uvedeny ukázky vlnky Daubechies rodiny zleva $db2$, $db5$ a $db10$ [56].



Obrázek 27: Jednotlivé druhy vlněk rodiny Dabechies [56].

Symlets vlnky

Symlety jsou téměř symetrické vlnky, které jsou navrženy jako modifikace Daubechies vlněk. Jejich vlastnosti jsou si podobné. Jsou popsány $symN$, přičemž N značí pořadí a sym pojednává o příjmení vlnky. Níže jsou uvedeny ukázky vlnky Symlet rodiny zleva $sym2$, $sym5$ a $sym8$ [56].



Obrázek 28: Jednotlivé druhy Symlets vlněk [56].

4.4.1 Spojitá vlnková transformace

Hlavní myšlenkou vlnkové transformace je vhodná změna šířky a tvaru okna v čase. K popisu je možno použít rovnici(39), kde τ je translační škálovací parametr udávající polohu vlnky v čase, s je dilatační škálovací parametr, který udává šířku vlnky. Zlomek $\frac{1}{\sqrt{s}}$ provádí normalizaci energie mateřské vlnky ψ v případě změny měřítka. Pro signály s finitní energií je definována dle rovnice(40). Přičemž $Wf_{(\tau,s)}$ se nazývají vlnkové koeficienty a $\bar{\psi}$ vyjadřuje komplexně sdružené číslo. Po dosažení získáme tvar(41) [54]:

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{s}}\psi \cdot \left(\frac{t-\tau}{s}\right) \quad s, \tau \in \mathbf{R}, \quad s \neq 0 \quad (39)$$

$$Wf_{(\tau,s)} = \int_{-\infty}^{\infty} f(t)\overline{\psi_{\tau,s}(t)}dt \quad (40)$$

$$Wf_{(\tau,s)} = \int_{-\infty}^{\infty} f(t)\frac{1}{\sqrt{s}}\bar{\psi}\left(\frac{t-\tau}{s}\right)dt \quad (41)$$

Grafické znázornění vlnkových koeficientů v rovině (τ, s) je častokrát nazýván jako scalogram, či vlnková mapa [54].

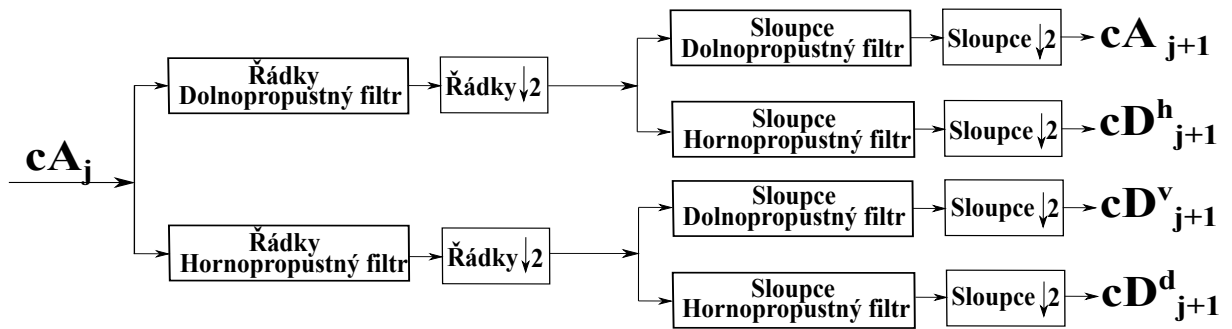
4.4.2 2D Diskrétní vlnková transformace

Diskrétní vlnková transformace byla zavedena jako vysoce účinná a flexibilní metoda pro rozložení signálů v jednotlivých subprostorech. 2D DWT je v současné době jednou z klíčových operací při zpracování obrazu. Jedná se o analýzu s více rozlišovacími schopnostmi, která rozkládá obrazy na vlnkové koeficienty a škálovací funkci²⁷. V diskrétní vlnkové transformaci se energie signálu soustředí na specifické vlnkové koeficienty. Analyzovaný signál prochází filtry s různými frekvencemi o rozdílných škálách, přičemž je možné poměrně snadně redukovat výpočetní čas. 2D DWT lze chápat jako schéma jednodimenzionálních vlnových délek, které transformují podél řádků, a potom 1D vlnku transformující podél sloupců, jak je znázorněno na obr. 29 [57]. DWT může být implementována jako vícestupňová transformace. Aplikací diskrétní vlnkové transformace se rozkládá vstupní obraz do frekvenčních dílčích pásem, která se označují jako:

- **LL** - aproximaci
- **LH** - horizontální detaily
- **HL** - vertikální detaily
- **HH** - diagonální detaily

²⁷Škálováním se jednoduše rozumí protahování nebo komprese vlnky. Škálování je definováno tzv. škálovacím faktorem, často označovaným písmenem α . Čím menší bude tento faktor, tím více bude vlnka kompresována [56].

Kde LH, HL a HH představují koeficienty vlnky nejjemnějšího měřítka a LL koeficienty hrubé úrovně. Tato dílčí pásma obsahují různé informace o obrázku. Nejnižší frekvenční pásmo LL, které je získáno filtrem dolního propustu, odpovídá hrubé aproximaci obrazového signálu. Podřízené pásma odpovídají všem detailům 2D signálu. Subpásma LL může být dále rozloženo, aby se dosáhlo vyššího stupně rozkladu. Proces rozkladu pokračuje v dílčím pásmu LL, dokud se nedocílí požadovaného počtu určených úrovní. Experimentálně bylo zjištěno, že lidské oči jsou mnohem citlivější na část s nízkou frekvencí (subpásma LL) [57, 58].



Obrázek 29: Základní fáze 2D vlnkové transformace pomocí banky filtrů [59].

Jediná fáze rozkladu vytváří čtyři obrazy, z toho tři jsou detailní obsahující horizontální, vertikální a diagonální detaily obrazu a jednu hrubou aproximaci původního obrazu, která se rozkládá dále dle zvoleného stupně rozkladu. Jak znázorňuje obr. 29, dochází k rozkladu řádků a sloupců pomocí dolnoproústného a hornoproústného filtru, přičemž dochází k podvzorkování. Hrubá aproximace může být potom dále rozložena podobným postupem [59].

4.4.3 Prahování vlnkových koeficientů

Donoho a Johnstone ve své studii z roku 1995 [47] propagovali práci na filtrování aditivního Gaussova šumu pomocí prahování vlnkových koeficientů. Vlnky hrají významnou roli v kompresi obrazu a eliminaci šumu z obrazu. Vzhledem k tomu, že tématem práce je filtrace šumu z obrazu, je tato aplikace podrobně diskutována. Vlnkové koeficienty, vypočtené vlnkovou transformací, představují změnu v časové řadě při určitém rozlišení, proto je možné odfiltrovat šum. Vlnkovým prahováním je myšlena dekompozice dat nebo obrazu do vlnkových koeficientů, porovnání detailních koeficientů s danou prahovou hodnotou a zmenšení těchto koeficientů na nulu, aby se odstranil vliv šumu v datech. Obraz je poté následně rekonstruován z upravených koeficientů. Tento proces je také známý jako inverzní diskretní vlnková transformace. Během prahování je koeficient vlnky porovnán s daným prahem, a pokud je jeho velikost menší než prahová hodnota, tak je vynulován. V opačném případě je zachován nebo upraven v závislosti na pravidlu prahové hodnoty. Prahování rozlišuje koeficienty poškozeny šumem, a koeficienty které obsahují důležité informace o signálu.

Důležitým bodem je volba prahu, jelikož hraje významnou roli pro odstraňování šumu z obrazu. Filtrace šumu nejčastěji produkuje vyhlazené obrazy, což snižuje jejich ostrost. Je třeba

dbát na to, aby byly zachovány hrany filtrovaného obrazu. Existují některé metody, které jsou závislé na volbě prahu, například tzv. VisuShrink, SureShrink a BayesShrink, které byly popsány v podkapitole 3.2.3. Obecně prahování lze rozdělit do dvou kategorií na tvrdé a měkké [47, 48, 60].

Tvrdé prahování

Tato procedura nuluje koeficienty, které jsou pod úrovní nastaveného prahu, zatímco koeficienty nad touto úrovní jsou ponechány beze změn. Jedná se o tzv. proceduru ponechej nebo odstraň. K popisu je možno použít rovnici [53]:

$$\delta_{\lambda}^H(\hat{d}_{jk}) = \begin{cases} 0 & \text{if } |\hat{d}_{jk}| \leq \lambda \\ \hat{d}_{jk} & \text{if } |\hat{d}_{jk}| > \lambda \end{cases} \quad (42)$$

Kde \hat{d}_{jk} označuje vlnkové koeficienty a λ prahovou hodnotu. Pokud budou hodnoty pod touto úrovní dojde k jejich nulování [53].

Měkké prahování

Při měkkém prahování se koeficienty s větší hodnotou než je hodnota prahu posunou směrem k nule. Koeficienty, které jsou menší než hodnota prahu jsou opět vynulovány. Definovat lze jako [53]:

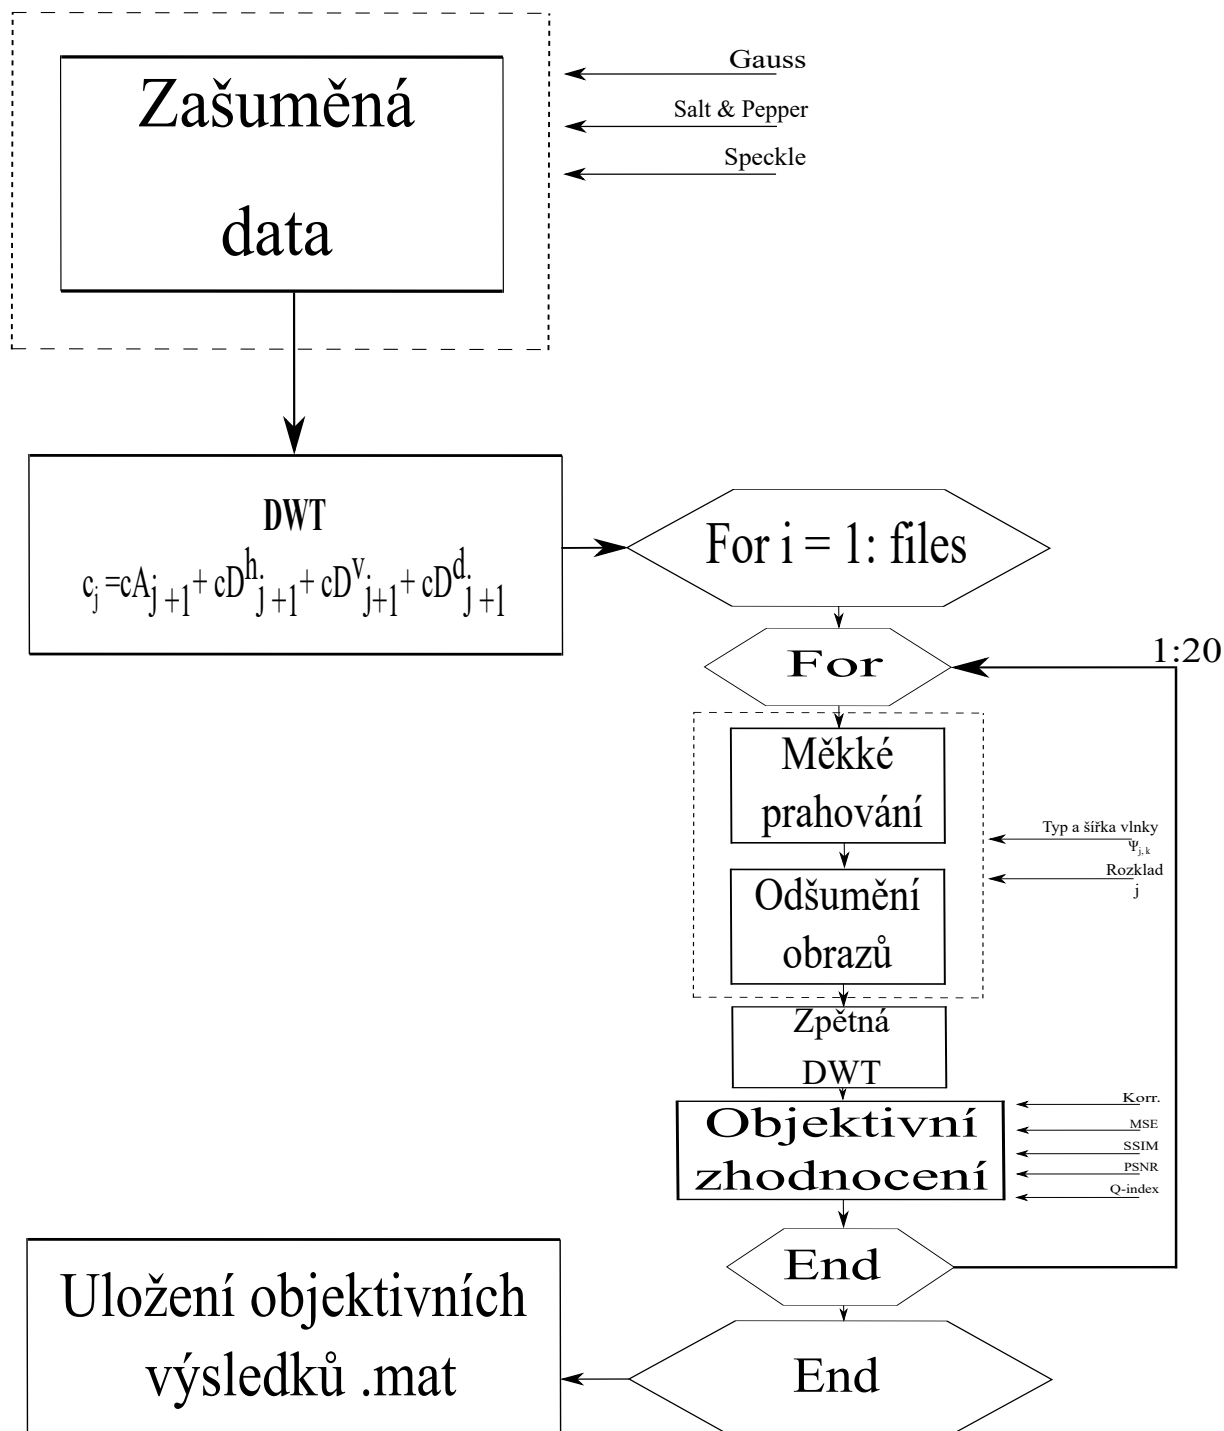
$$\delta_{\lambda}^S(\hat{d}_{jk}) = \begin{cases} 0 & \text{if } |\hat{d}_{jk}| \leq \lambda \\ \hat{d}_{jk} - \lambda & \text{if } \hat{d}_{jk} > \lambda \\ \hat{d}_{jk} + \lambda & \text{if } \hat{d}_{jk} < -\lambda \end{cases} \quad (43)$$

Kde \hat{d}_{jk} značí vlnkové koeficienty a λ prahovou hodnotu. Pokud budou hodnoty pod touto úrovní dojde k jejich nulování [53].

4.5 Vlastní filtrace

V praktické části realizace filtrace šumu byla v prostředí Matlab testována vlnková transformace. Vlnky byly testovány na vytvořených klinických obrazech, které obsahují ultrazvukové snímky břicha, krku a karotid. Jednotlivé databáze jsou popsány v kapitole 4.2. V prvním kroku je zvolen typ vlnky. Zde bylo testováno vlnky rodiny *Daubechies* a *Symlets* popsány v kap. 4.4. Testováno bylo 8 typů vlněk z rodiny *Daubechies* (*db2*, *db5*, *db10*, *db15*, *db20*, *db22*, *db25* a *db30*) a 8 typů z rodiny *Symlets* (*sym2*, *sym3*, *sym5*, *sym10*, *sym15*, *sym20*, *sym25* a *sym29*). Vstupní obraz je rozložen na aproximační a detailní složky podle nastavené úrovně dekompozice a typu vlnky. Zde byla testována úroveň rozkladu 3 a 4. V dalším kroku je zvoleno měkké prahování pomocí *sorh*. Ke stanovení prahových hodnot je použita strategie Birgé-Massart [61]. Tato strategie je zvolena na základě její schopnosti zachování hran, při procesu filtrace. Na závěr je funkce *wdencomp*, která provádí proces odšumění podle nastavených parametrů. Výsledkem je

filtrovaný obraz, který je posuzován na základě vybraných objektivních parametrů. Jako objektivní parametry pro posouzení kvality byly zvoleny: korelace, střední kvadratická chyba (MSE), index strukturální podobnosti (SSIM), špičkový poměr signálu k šumu (PSNR) a univerzální index quality obrazu (Q-index). Objektivní parametry byly popsány v kap. 2.4.2.



Obrázek 30: Základní fáze 2D vlnkové transformace pomocí banky filtrů [59].

5 Hodnocení filtrace variantních typů šumu na reálných klinických datech

Tato část je zaměřena na hodnocení vlnkové transformace pro filtraci variantních typů šumů na reálných klinických ultrazvukových datech. Budou zde popsány výsledky testování pro Gaussovský, Salt and Pepper a Speckle šum. Filtrace bude testována na všech vytvořených databázích. Data byla vytvořena pomocí přístroje viz kap. 4.1 a popsána v kap. 4.2. Bylo testováno 220 ultrazvukových dat, která byla rozdělena do třech databází. Mezi objektivní parametry hodnotící kvalitu obrazové filtrace byly zvoleny korelace, MSE²⁸, PSNR²⁹, SSIM³⁰ a Q-index³¹, které byly podrobněji popsány v kap. 2.4.2. Hodnocení bylo provedeno pro každý snímek, z nichž byl vytvořen průměr za účelem přehledného zobrazení. Algoritmus byl popsán v kapitole 4.5.

Níže bude uvedená názorná část testování pro rodinu vlnek *Daubechies* o úrovni rozkladu 3. Výsledky testování vlnek *Daubechies* o úrovni rozkladu 4 budou součástí příloh. Testování efektivity filtrace pomocí rodiny *Symlets* o úrovni rozkladu 3 a 4 bude součástí příloh z důvodu výrazného přesahu obsahu této diplomové práce.

²⁸Střední kvadratická chyba.

²⁹špičkový poměr signálu k šumu.

³⁰Index strukturální podobnosti obrazu.

³¹Univerzální index kvality obrazu.

5.1 Výsledky filtrace pro Gaussův šum

Popis a ukázka zašuměných dat Gaussovských šumem byla uvedena v kap. 4.3.1. Gaussův šum je popsán parametry rozptylu σ^2 a střední hodnoty μ . Níže jsou uvedené výsledky testování jednotlivých databází.

5.1.1 Výsledky databáze břicho

Efektivnost filtrace z databáze karotidy vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 31 a ukázka číselné charakteristiky vybraných parametrů je zobrazena v tab. 1. Obrázek je popsán objektivními parametry, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Obr. 31 a) popisuje korelaci mezi obrazy. Lze si povšimnout lineární závislosti korelace s rostoucí úrovní šumu. Při nejnižší úrovni Gaussova šumu ($\sigma^2 = 0.01$, $\mu = 0.01$) nejlepší filtraci vykazuje vlnka typu *db2*. S rostoucí úrovní šumu znázorňuje lepší korelaci vlnka typu *db5* a to i při nejvyšší nastavené úrovni ($\sigma^2 = 0.01$, $\mu = 0.2$).

Obr. 31 b) znázorňuje střední kvadratickou chybu. Lze vidět stoupající trend se zvyšující se úrovní šumu. Opět se nejlépe jeví vlnka typu *db5*.

Na obr. 31 c) se vyobrazuje špičkový poměr signálu k šumu. Je možno sledovat stejnou závislost se stoupající úrovní šumu. Vlnka *db5* je opět nejefektivnější.


Obr. 31 d) popisuje strukturální podobnost dvou obrazů. Lze posuzovat obdobnou závislost s rostoucí úrovní šumu, přičemž nejlépe se jeví i při nejnižší úrovni šumu vlnka typu *db5*.

Poslední obr. 31 e) je popsán objektivním parametrem Q-indexu. Nejlépe se jeví při nejnižší úrovni šumu vlnka typu *db10*.


Z těchto výsledků lze posoudit, že nejpříjemněji se jeví vlnka typu *db5*, a to i při vyšších úrovních šumu. To je prokázáno i dle tab. 1. Naopak nejhůře se jeví vlnka *db30*. Výsledky vybraných objektivních parametrů korelace, MSE a SSIM je zobrazena v tab. 1. Vlnka vykazující největší efektivitu dle vybraného parametru při dané úrovni šumu je znázorněna tučným písmem.

Tabulka 1: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze břicho.


	Gaussovský šum; $\mu = 0.01$			Gaussovský šum; $\mu = 0.1$			Gaussovský šum; $\mu = 0.2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9481	211.82	0.4654	0.9301	886.25	0.3947	0.9147	2809.1	0.3313
<i>db5</i>	0.9476	211.04	0.4731	0.9320	879.91	0.4015	0.9179	2799.5	0.3374
<i>db10</i>	0.9443	220.25	0.4714	0.9284	889.62	0.4002	0.9140	2809.7	0.3362
<i>db15</i>	0.9422	225.11	0.4708	0.9268	893.25	0.3999	0.9128	2812.0	0.3361
<i>db20</i>	0.9405	229.16	0.4705	0.9255	896.46	0.3997	0.9119	2814.5	0.3360
<i>db22</i>	0.9402	230.11	0.4702	0.9247	898.29	0.3996	0.9109	2816.6	0.3358
<i>db25</i>	0.9394	232.40	0.4697	0.9241	900.01	0.3990	0.9102	2818,4	0,3353
<i>db30</i>	0.9385	234.54	0.4686	0.9248	902.02	0.3982	0.9095	2820.1	0.3346




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 31: Porovnání výsledků filtrace Gaussovského šumu pomocí vlněk rodiny Daubechies pro snímky z databáze břicho.

5.1.2 Výsledky databáze karotidy

Filtrace z databáze karotidy pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 32. Ukázka číselných charakteristik vybraných parametrů je zobrazena v tab. 2. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Na obr. 32 a) je zobrazena korelace. Lze si povšimnout lineární závislosti korelace s rostoucí úrovní šumu. Nejlepší filtrace je vykazována vlnkou typu *db5*, a to i při nejnižší úrovni šumu.

Obr. 32 b) znázorňuje střední kvadratickou chybu. Zde vidíme stoupající trend se zvyšující se úrovní šumu. Opět se nejlépe jeví vlnka typu *db5*.

Na obr. 32 c) je vyobrazen špičkový poměr signálu k šumu. Je možno sledovat stejnou závislost se stoupající úrovní šumu. Vlnka *db5* se jeví nejefektivněji.


Obr. 32 d) popisuje strukturální podobnost dvou obrazů. Je možno usuzovat obdobnou závislost s rostoucí úrovní šumu, přičemž nejlépe se jeví vlnka typu *db5*.

Poslední obr. 32 e) obsahuje objektivní parametr Q-indexu, kde se nejlépe jeví při nejnižší úrovni šumu vlnka typu *db22*, která následně klesá a poté při úrovni 4 ($\sigma^2 = 0.01$, $\mu = 0.04$) je opět nejefektivnější.


Z těchto výsledků lze posuzovat, že nepřijatelněji se jeví opět vlnka typu *db5*, a to i při vyšších úrovních šumu. Vlnku *db5* lze určit za nejefektivnější i z vybraných objektivních parametrů znázorněných v tab. 2.

Tabulka 2: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze karotidy.


	Gaussovský šum; $\mu = 0.01$			Gaussovský šum; $\mu = 0.1$			Gaussovský šum; $\mu = 0.2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9305	260.47	0.5362	0.9124	940.93	0.3989	0.9019	2863.0	0.3074
<i>db5</i>	0.9320	254.44	0.5485	0.9154	930.54	0.4105	0.9051	2851.2	0.3167
<i>db10</i>	0.9281	264.57	0.5465	0.9119	940.50	0.4098	0.9015	2862.7	0.3160
<i>db15</i>	0.9260	268.96	0.5455	0.9101	943.58	0.4095	0.9003	2864.1	0.3159
<i>db20</i>	0.9235	275.24	0.5442	0.9080	948.72	0.4086	0.8983	2868.3	0.3153
<i>db22</i>	0.9229	276.60	0.5435	0.9073	950.41	0.4083	0.8977	2870.0	0.3152
<i>db25</i>	0.9218	279.84	0.5429	0.9064	953.12	0.4080	0.8969	2872.7	0.3149
<i>db30</i>	0.9209	281.91	0.5417	0.9060	954.60	0.4071	0.8966	2874.1	0.3144




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 32: Porovnání výsledků filtrace Gaussovského šumu pomocí vlněk rodiny Daubechies pro snímky z databáze karotidy.

5.1.3 Výsledky databáze krk

Efektivnost filtrace z databáze krk pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 33. Ukázka číselných charakteristik vybraných parametrů je vyobrazena v tab. 3. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Na obr. 33 a) je zobrazen objektivní parametr korelace. Zde si můžeme povšimnout, že nejlépe se celkově jeví vlnka typu *db5*.

Obr. 33 b) znázorňuje střední kvadratickou chybu mezi obrazem referenčním a filtrovaným. Zde je patrný stoupající trend se zvyšující se úrovní šumu. Dle parametru MSE lze těžce usuzovat, která vlnka je nejefektivnější. Avšak je vidět, že nejefektivněji se jeví *db5*.

Na obr. 33 c) je vyobrazen špičkový poměr signálu k šumu. Lze sledovat stejnou závislost se stoupající úrovní šumu. Obdobně jako u parametru MSE se opět se jeví nejlépe *db5*.


Obr. 33 d) je popsán strukturální podobnost mezi referenčním obrazem a filtrovaným. Zde je možno vidět obdobnou závislost s rostoucí úrovní šumu, přičemž nejlépe se jeví vlnka typu *db10*.

Poslední obr. 33 e) zobrazuje objektivní parametr Q-indexu, kde se nejlépe jeví při nejnižší úrovni šumu vlnka typu *db15*. Mírný výkyv lze pozorovat při úrovni šumu 3 ($\sigma^2 = 0.01$, $\mu = 0.03$).


Z těchto výsledků lze vidět, že nejpříjemněji se jeví opět vlnka typu *db5*, a to i při vyšších úrovních šumu. Je možno usuzovat i dle vybraných parametrů znázorněných v tab. 3.

Tabulka 3: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Gaussova šumu pro UZ snímky databáze krk.


	Gaussovský šum; $\mu = 0.01$			Gaussovský šum; $\mu = 0.1$			Gaussovský šum; $\mu = 0.2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9236	261.39	0.6301	0.9107	928.86	0.5501	0.8974	2864.4	0.4651
<i>db5</i>	0.9252	254.85	0.6433	0.9137	918.46	0.5629	0.9013	2851.4	0.4761
<i>db10</i>	0.9224	262.39	0.6432	0.9108	926.62	0.5629	0.8984	2859.9	0.4762
<i>db15</i>	0.9199	268.84	0.6415	0.9088	931.78	0.5617	0.8968	2864.0	0.4753
<i>db20</i>	0.9179	273.64	0.6409	0.9070	935.94	0.5613	0.8952	2867.4	0.4750
<i>db22</i>	0.9176	274.80	0.6404	0.9064	937.66	0.5609	0.8946	2869.3	0.4747
<i>db25</i>	0.9168	276.82	0.6398	0.9060	938.67	0.5608	0.8942	2869.9	0.4745
<i>db30</i>	0.9159	279.24	0.6389	0.9052	941.04	0.5600	0.8936	2872.1	0.4740




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.


Obrázek 33: Porovnání výsledků filtrace Gaussovského šumu pomocí vlnek rodiny Daubechies pro snímky z databáze krk.

5.1.4 Shrnutí efektivity vlnek pro Gaussův šum


Podle výsledků testování efektivity kooperativních vlnek rodiny *Daubechies* lze vidět, že nejefektivněji se jeví vlnka typu *db5* nejhůře vlnka typu *db30* viz obr. 34. Na obrázku je patrné výraznější rozmazání obrazu při vlnce typu *db30*. Mírné výkyvy lze pozorovat u hodnotícího parametru Q-indexu, kde se při nižších hodnotách šumu jeví lépe rozdílné typy vlnek. Jak bylo očekáváno, tak se zvyšující se úroveň šumu účinnost filtrace klesá. Lépe lze tento závěr pozorovat pomocí objektivního parametru korelace, kde účinnost lineárně klesá se zvyšující se úrovní šumu. Nejlepší strukturální podobnosti a Q-indexu je dosaženo v databázi krk.



(a) Obraz znázorňující originální nezašuměný snímek břicha.



(b) Obraz popisující zašuměný snímek břicha Gaussovským šumem o $\sigma^2 = 0.01$, $\mu = 0.2$.



(c) Obraz vyobrazuje filtrovaný obraz pomocí *db5*.



(d) Obraz vyobrazuje filtrovaný obraz pomocí *db30*.

Obrázek 34: Výstup filtrovaného obrazu zašuměného Gaussovským šumem.

5.2 Výsledky filtrace pro Salt and Pepper šum

Popis a ukázka zašuměných dat šumem Sůl a Pepř byla uvedena v kap. 4.3.2. Salt and Pepper šum je popsán parametrem hustoty šumu d . Níže budou uvedené výsledky testování jednotlivých databází.

5.2.1 Výsledky databáze břicho

Efektivnost filtrace z databáze břicho pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 35. Tab. 4 znázorňuje číselné charakteristiky pro objektivní parametry korelace, MSE a SSIM. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Na obr. 35 a) lze pozorovat korelaci, kde se nejefektivněji jeví vlnka typu *db30*. S rostoucí úrovní šumu klesá efektivita této vlnky a při nejvyšší úrovni šumu ($d = 0.02$) se jeví nejlépe *db22*.


Obr. 35 b) znázorňuje střední kvadratickou chybu. Zde je patrný stoupající trend se zvyšující se úrovní šumu *db30* se opět jeví nejlépe.

Na obr. 35 c) je vyobrazen špičkový poměr signálu k šumu. Lze sledovat obdobnou závislost se stoupající úrovní šumu, přičemž vlnka *db30* je nejefektivnější, avšak při rostoucí úrovni šumu ztrácí svou efektivitu.


Obr. 35 d) popisuje strukturální podobnost. Vlnka *db2* působí celkově nejefektivněji, avšak při vyšší úrovni šumu klesá efektivnost a jeví se lépe vlnka typu *db30*.

Na posledním obr. 35 e) je zobrazen objektivní parametr Q-indexu, kde se nejlépe jeví vlnka typu *db2*, a to i při vyšších úrovni šumu.


Z těchto výsledků je patrný nejefektivnější typ vlnky *db30*, avšak při vyšších úrovni šumu efektivita kolísá. Dle určitých objektivních parametrů se nejhůře jeví vlnka *db2*. Dle tab. 4 lze pozorovat, že při vyšší úrovni šumu největší korelaci vyjadřuje vlnka *db22* a nejnižší MSE vlnka typu *db20*. Vlnka vykazující největší efektivitu při dané úrovni šumu, dle vybraného parametru, je znázorněna tučným písmem.




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 35: Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlněk rodiny Daubechies pro snímky z databáze břicho.

Tabulka 4: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze břicho.

	Salt and Pepper; $d = 0.001$			Salt and Pepper; $d = 0.01$			Salt and Pepper; $d = 0.02$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9906	26.510	0.9644	0.9196	249.79	0.7509	0.8561	488.89	0.5750
<i>db5</i>	0.9908	25.955	0.9639	0.9253	226.80	0.7361	0.8794	379.84	0.5455
<i>db10</i>	0.9912	24.747	0.9577	0.9444	159.20	0.6891	0.9346	185.49	0.5217
<i>db15</i>	0.9913	24.410	0.9624	0.9556	124.75	0.6745	0.9504	142.62	0.5521
<i>db20</i>	0.9916	23.521	0.9529	0.9610	109.26	0.6692	0.9557	130.05	0.5841
<i>db22</i>	0.9918	23.037	0.9552	0.9675	92.775	0.6631	0.9561	130.61	0.6110
<i>db25</i>	0.9920	22.319	0.9480	0.9693	88.663	0.6715	0.9549	134.46	0.6244
<i>db30</i>	0.9923	21.548	0.9456	0.9705	86.775	0.6845	0.9516	143.74	0.6408

5.2.2 Výsledky databáze karotidy

Efektivnost filtrace z databáze karotidy pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 36. Číselné charakteristiky vybraných objektivních parametrů jsou znázorněny v tab. 5.

Na obr. 36 a) je patrné, že nejlépe si činí vlnka typu *db30*. S rostoucí úrovní šumu klesá efektivita této vlnky a při nejvyšší úrovni šumu ($d = 0.02$) se jeví nejlépe *db20*.


Obr. 36 b) znázorňuje střední kvadratickou chybu mezi obrazem referenčním a filtrovaným. Zde je patrný stoupající trend se zvyšující se úrovní šumu. *db30* se opět jeví nejlépe při nižších úrovních šumu. Při vyšších opět *db20*.

Na obr. 36 c) je vyobrazen špičkový poměr signálu k šumu. Lze sledovat obdobnou závislost se stoupající úrovní šumu. Obdobně jako u předešlých objektivních parametrů při nižší úrovni šumu vlnka typu *db30* a vyšší je nejefektivnější vlnka typu *db20*.


Obr. 36 d) popisuje strukturální podobnost. Vlnka *db2* působí celkově nejefektivnější, avšak při vyšší úrovni šumu klesá efektivnost a jeví se lépe vlnka typu *db30*.

Na posledním obr. 36 e) je zobrazen objektivní parametr Q-indexu, kde se nejlépe jeví vlnka typu *db2*. Avšak při určitých úrovních šumu je možné pozorovat významné výkyvy efektivity jednotlivých vlnek. Při nejvyšší úrovni šumu ($d = 0.02$) je možno usuzovat nejefektivnější typ vlnky *db10*.


Ze znázorněných výsledků je možno odvodit nejefektivnější typ vlnky *db30* při nižší úrovni šumu viz tab. 5. Při vyšších úrovních šumu kolísá a nejefektivněji se ukazuje vlnka typu *db20*, kromě parametru SSIM, dle kterého je opět nejúčinnější vlnka *db30* viz tab. 5. Naopak nejhůře se jeví vlnka *db2*.




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 36: Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlněk rodiny Daubechies pro snímky z databáze karotidy.

Tabulka 5: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze karotidy.

	Salt and Pepper; $d = 0.001$			Salt and Pepper; $d = 0.01$			Salt and Pepper; $d = 0.02$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9902	28.365	0.9565	0.9214	248.19	0.7737	0.8610	478.66	0.6193
<i>db5</i>	0.9906	27.161	0.9591	0.9266	227.27	0.7653	0.8802	386.66	0.6002
<i>db10</i>	0.9910	25.938	0.9549	0.9428	167.68	0.7296	0.9274	209.82	0.5764
<i>db15</i>	0.9912	25.185	0.9588	0.9524	136.62	0.7177	0.9405	172.31	0.5999
<i>db20</i>	0.9913	24.899	0.9518	0.9565	124.18	0.7133	0.9441	164.12	0.6258
<i>db22</i>	0.9915	24.315	0.9525	0.9608	112.80	0.7053	0.9424	170.11	0.6473
<i>db25</i>	0.9916	24.084	0.9485	0.9616	111.19	0.7109	0.9402	176.73	0.6581
<i>db30</i>	0.9918	23.555	0.9458	0.9614	113.13	0.7199	0.9352	190.94	0.6703

5.2.3 Výsledky databáze krk

Účinnost filtrace z databáze krk pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 37. Vybrané parametry jsou také znázorněny v tab. 6. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Na obr. 37 a) je patrné, že nejlépe si činí vlnka typu *db30*. S rostoucí úrovní šumu klesá efektivita této vlnky a při nejvyšší úrovni šumu ($d = 0.02$) se jeví nejlépe *db20*.


Obr. 37 b) znázorňuje střední kvadratickou chybu mezi obrazem referenčním a filtrovaným. Zde je patrný stoupající trend se zvyšující se úrovní šumu. *db30* se opět jeví nejlépe při nižších úrovních šumu. Při vyšších opět *db20*.

Na obr. 37 c) je vyobrazen špičkový poměr signálu k šumu. Lze sledovat obdobnou klesající závislost se stoupající úrovní šumu. Obdobně jako u předešlých objektivních parametrů při nižší úrovni šumu je efektivnější vlnka typu *db30* a vyšší vlnka typu *db20*.


Obr. 37 d) popisuje strukturální podobnost. Vlnka *db2* připadá celkově nejefektivnější, avšak při vyšší úrovni šumu klesá efektivnost a jeví se lépe vlnka typu *db30*.

Na posledním obr. 37 e) je zobrazen objektivní parametr Q-indexu, kde se nejlépe jeví vlnka typu *db2*. Avšak při určitých úrovních šumu lze pozorovat významné výkyvy efektivity jednotlivých vlnek.


Z těchto výsledků je možno odvodit nejefektivnější typ vlnky při nižší úrovni šumu *db30*. Při vyšších úrovních šumu kolísá a nejvyšší korelaci a nízkou MSE představuje vlnka typu *db20*. Naopak nejhůře se jeví vlnka *db2* krom parametru SSIM při úrovni šumu 10 ($d = 0.01$) viz tab. 6.




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.


Obrázek 37: Porovnání výsledků filtrace Salt and Pepper šumu pomocí vlněk rodiny Daubechies pro snímky z databáze krk.

Tabulka 6: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Salt and Pepper šumu pro UZ snímky databáze krk.


	Salt and Pepper; $d = 0.001$			Salt and Pepper; $d = 0.01$			Salt and Pepper; $d = 0.02$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9916	25.102	0.9574	0.9305	222.07	0.7609	0.8757	426.16	0.6005
<i>db5</i>	0.9919	24.234	0.9582	0.9364	198.71	0.7553	0.8980	325.63	0.5957
<i>db10</i>	0.9923	23.010	0.9532	0.9529	140.06	0.7320	0.9403	176.71	0.6067
<i>db15</i>	0.9925	22.323	0.9579	0.9611	114.82	0.7279	0.9495	152.72	0.6442
<i>db20</i>	0.9926	21.958	0.9502	0.9647	104.61	0.7283	0.9511	150.49	0.6770
<i>db22</i>	0.9928	21.357	0.9513	0.9670	99.604	0.7297	0.9492	157.61	0.6984
<i>db25</i>	0.9929	21.139	0.9469	0.9676	99.103	0.7393	0.9471	163.97	0.7085
<i>db30</i>	0.9931	20.639	0.9446	0.9667	103.30	0.7523	0.9424	178.18	0.7197

5.2.4 Shrnutí efektivity vlnek pro Salt and Pepper šum

Podle výsledků testování efektivity kooperativních vlnek rodiny *Daubechies* lze vyvodit, že nejefektivněji se při nižší úrovni šumu jeví vlnka typu *db30*. Se stoupající úrovní šumu lze vidět rostoucí efektivitu vlnky *db20*. Vlnka typu *db2* vykazuje nejmenší efektivitu viz obr. 37. Na obrázku je patrné potlačení šumu. Na vlnce typu *db20* je patrné větší rozmázení obrazu. Výrazné výkyvy efektivity kooperativních vlnek lze pozorovat u hodnotícího parametru Q-indexu. Při rozdílných úrovních šumu připadá lepší efektivita rozdílným typům vlnek. Jak bylo předpokládáno, se zvyšující se úrovní šumu klesá účinnost filtrace. Lépe lze tento závěr pozorovat pomocí objektivního parametru korelace, kde účinnost lineárně klesá se zvyšující se úrovní šumu.



(a) Obrázek znázorňující originální nezašuměný snímek krku. (b) Obrázek popisující zašuměný snímek krku Salt and Pepper šumem o $d = 0.02$.



(c) Obrázek vyobrazuje filtrovaný obraz pomocí $db30$. (d) Obrázek vyobrazuje filtrovaný obraz pomocí $db20$.

Obrázek 38: Výstup filtrovaného obrazu zašuměného Salt and Pepper šumem.

5.3 Výsledky filtrace pro Speckle šum

Tato podkapitola je věnována výsledkům filtrace Speckle šumu. Popis a ukázka zašuměných dat šumem Speckle byla uvedena v kap. 4.3.3. Speckle šum je popsán odchylkou σ . Níže budou uvedené výsledky testování jednotlivých databází.

5.3.1 Výsledky databáze břicho

Efektivnost filtrace z databáze břicho pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 39 a vybrané objektivní parametry znázorněny v tab. 7. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Dle parametru korelace si lze povšimnout největší efektivity vlnky $db2$ viz obr. 39 a).

Obr. 39 b) znázorňuje střední kvadratickou chybu mezi obrazem referenčním a filtrovaným. Zde se opět jeví nejlépe při vlnce typu *db2*.

db2 je také nejúčinnější dle špičkového poměru signálu k šumu, který je znázorněn na obr. 39 c).


Obr. 39 d) popisuje strukturální podobnost. Vlnka *db2* působí celkově nejefektivněji.

Na posledním obr. 39 e) je zobrazen objektivní parametr Q-indexu, kde se nejlépe jeví vlnka typu *db2*.


Z dosažených výsledků je možno odvodit, že jednoznačně se nejefektivněji jeví typ vlnky *db2*. Nejhorší efektivita je vykazována vlnkami *db20* a *db30*. Efektivnost *db2* je prokazatelná u všech zvolených objektivních parametrů. I podle vybraných objektivních parametrů uvedených v tab. 7. Vlnka vykazující největší efektivitu dle vybraného parametru při dané úrovni šumu je znázorněna tučným písmem.

Tabulka 7: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze břicho.


	Speckle; $d = 0.1$			Speckle; $d = 1$			Speckle; $d = 2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9667	94.95	0.8036	0.8195	539.68	0.5966	0.7779	774.06	0.5504
<i>db5</i>	0.9659	97.29	0.7934	0.8114	574.31	0.5775	0.7675	832.00	0.5315
<i>db10</i>	0.9648	100.61	0.7822	0.8040	603.85	0.5580	0.7580	880.46	0.5127
<i>db15</i>	0.9642	102.40	0.7758	0.8001	620.19	0.5477	0.7527	909.27	0.5017
<i>db20</i>	0.9641	102.54	0.7742	0.8010	615.07	0.5436	0.7529	906.23	0.4969
<i>db22</i>	0.9641	102.79	0.7730	0.8006	615.76	0.5421	0.7525	906.65	0.4950
<i>db25</i>	0.9641	102.69	0.7723	0.8014	610.99	0.5399	0.7533	899.76	0.4927
<i>db30</i>	0.9643	102.48	0.7714	0.8033	601.94	0.5388	0.7554	885.15	0.4910




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 39: Porovnání výsledků filtrace Speckle šumu pomocí vlněk rodiny Daubechies pro snímky z databáze břicho.

5.3.2 Výsledky databáze karotidy

Efektivnost filtrace z databáze karotidy pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 je znázorněna na obr. 40. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu. Vybrané objektivní parametry popisující efektivnost kooperativních vlnek jsou znázorněny v tab. 8.

Dle parametru korelace viz obr. 40 a) lze usoudit nejvyšší efektivitu *db30*, která vykazuje zároveň nejnížší úroveň MSE viz obr. 39 b).

Na obr. 40 c) je vyobrazen špičkový poměr signálu k šumu, na základě kterého se jeví opět nejlépe vlnka *db30*.


Podle parametru strukturální podobnosti obrazu obr. 40 d) lze vidět, že se zvyšující se úrovní šumu se zvyšuje efektivita filtrace vlnkou *db2*.

Na posledním obr. 40 e) je zobrazen objektivní parametr Q-indexu, lze pozorovat velmi rozptýlenou efektivitu jednotlivých vlnek. Je možno pozorovat, že při nižších úrovních šumu lze usoudit nejefektivnější vlnku typu *db5*. Při vyšší úrovni šumu *db2* a *db10*. Ovšem jednoznačně se dle tohoto parametru znázorňuje nejhorší efektivitu vlnka typu *db30*.


Na základě většiny objektivních parametrů lze přisoudit nejvyšší efektivitu *db30*, která se ovšem jeví nejhůře pomocí parametrů Q-indexu a SSIM viz tab. 8.

Tabulka 8: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze karotidy.


	Speckle; $d = 0.1$			Speckle; $d = 1$			Speckle; $d = 2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9592	121.49	0.8460	0.8088	605.25	0.6849	0.7754	778.37	0.6432
<i>db5</i>	0.9595	120.37	0.8487	0.8075	613.15	0.6817	0.7733	793.07	0.6397
<i>db10</i>	0.9596	120.10	0.8453	0.8083	607.16	0.6727	0.7742	785.19	0.6300
<i>db15</i>	0.9598	119.52	0.8432	0.8112	594.15	0.6683	0.7768	770.71	0.6249
<i>db20</i>	0.9599	119.23	0.8412	0.8148	577.27	0.6662	0.7810	748.22	0.6231
<i>db22</i>	0.9600	118.82	0.8409	0.8163	570.36	0.6656	0.7827	739.38	0.6228
<i>db25</i>	0.9601	118.78	0.8395	0.8177	563.23	0.6637	0.7842	729.57	0.6207
<i>db30</i>	0.9602	118.41	0.8372	0.8214	547.94	0.6619	0.7884	708.73	0.6196




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 40: Porovnání výsledků filtrace Speckle šumu pomocí vlnek rodiny Daubechies pro snímky z databáze karotidy.

5.3.3 Výsledky databáze krk

Níže je znázorněna efektivnost filtrace z databáze krk pomocí vlnek rodiny *Daubechies* o úrovni rozkladu 3 viz obr. 41. Vybrané parametry jsou také znázorněny v tab. 9. Objektivními parametry je popsán rozdíl mezi obrazem referenčním a filtrovaným, přičemž je pozorována efektivnost kooperativních vlnek v závislosti na úrovni šumu.

Na obr. 41 a) je vyobrazen průměr korelace. Nejefektivněji se jeví vlnka typu *db5*.

Efektivita *db5* je také potvrzena pomocí střední kvadratické chyby a špičkového poměru signálu k šumu viz obr. 41 b) a obr. 41 c).


Na základě strukturální podobnosti obrazů viz obr. 41 d) Je možno přisuzovat nejlepší efektivitu opět *db5*. O něco méně hůře se jeví vlnka *db2*.

Na posledním obr. 41 e) je zobrazen objektivní parametr Q-indexu, lze pozorovat velmi rozptýlenou efektivitu jednotlivých vlnek při variantních úrovních šumu. Nejvyšší efektivitu zde vykazuje vlnka typu *db2* a *db5*.


Na základě objektivních parametrů je zřejmé, že nejefektivnější filtraci v této databázi poskytuje vlnka typu *db5*, což lze pozorovat i u vybraných parametrů v tab. 9.

Tabulka 9: Číselné charakteristiky vybraných objektivních parametrů hodnotící kvalitu obrazové filtrace Speckle šumu pro UZ snímky databáze krk.


	Speckle; $d = 0.1$			Speckle; $d = 1$			Speckle; $d = 2$		
	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)	Korr.(-)	MSE(-)	SSIM(-)
<i>db2</i>	0.9531	145.34	0.8069	0.8323	474.12	0.6690	0.7985	614.86	0.6293
<i>db5</i>	0.9539	142.21	0.8112	0.8347	468.93	0.6702	0.8013	610.76	0.6304
<i>db10</i>	0.9525	146.27	0.8091	0.8320	476.50	0.6651	0.7992	617.71	0.6253
<i>db15</i>	0.9506	152.09	0.8029	0.8313	478.05	0.6591	0.7987	619.02	0.6195
<i>db20</i>	0.9490	156.87	0.7993	0.8307	478.80	0.6560	0.7982	618.78	0.6166
<i>db22</i>	0.9487	158.09	0.7987	0.8305	479.30	0.6558	0.7981	618.52	0.6168
<i>db25</i>	0.9480	159.86	0.7992	0.8303	479.37	0.6566	0.7979	618.43	0.6175
<i>db30</i>	0.9468	163.50	0.7979	0.8305	478.57	0.6581	0.7986	615.72	0.6195




(a) Graf znázorňující průměr korelace mezi referenčním obrazem a filtrovaným.




(b) Graf znázorňující průměr MSE mezi referenčním obrazem a filtrovaným.



(c) Graf znázorňující průměr PSNR mezi referenčním obrazem a filtrovaným.



(d) Graf znázorňující průměr SSIM mezi referenčním obrazem a filtrovaným.



(e) Graf znázorňující průměr Q-indexu mezi referenčním obrazem a filtrovaným.

Obrázek 41: Porovnání výsledků filtrace Speckle šumu pomocí vlněk rodiny Daubechies pro snímky z databáze krk.

5.3.4 Shrnutí efektivity vlnek pro Speckle šum

Podle výsledků testování efektivity kooperativních vlnek rodiny *Daubechies* lze usoudit, že výběr nejefektivnější vlnky je závislý na typu testovaného obrazu. Pro UZ obrazy z databáze břicho se nejefektivněji jeví vlnka typu *db2*, naopak nejhůře vlnka *db30* viz obr. 39. Ukázka filtrovaných obrazů z databáze břicho je znázorněna na obr. 42. Při testování databáze karotidy, typ vlnky *db2* nevykazuje účinnost jako v databázi břicho. Jevila se zde nejefektivněji vlnka typu *db30*, která v předešlé databázi byla nejméně efektivní. Efektivnost vlnky *db30* byla prokázána viz obr. 40, krom parametrů SSIM a Q-indexu. Ukázka filtrovaných obrazů pomocí kooperativních vlnek je zobrazena na obr. 43. V poslední testované databázi krk lze pozorovat nejvyšší efektivitu u vlnky *db5*, jak je znázorněno na obr. 40. Výstup filtrovaných obrazů z databáze krk je znázorněna na obr. 44.



(a) Obraz znázorňující originální nezašuměný UZ snímek břicha.



(b) Obraz popisující zašuměný snímek břicha Speckle šumem o $d = 2$.




(c) Obraz vyobrazuje filtrovaný obraz pomocí *db2*.




(d) Obraz vyobrazuje filtrovaný obraz pomocí *db30*.

Obrázek 42: Výstup filtrovaného obrazu zašuměného Speckle šumem.


Obr. 42 znázorňuje výstup filtrovaného obrazu pomocí vlněk *db2* a *db30*. Na obr. 42 a) lze vidět původní vytvořený UZ snímek z databáze břicho, obr. 42 b) znázorňuje totožný obraz uměle zašuměný speckle šumem o hustotě $d = 2$. Obr. 42 c) ukazuje výstup filtrovaného obrazu pomocí vlnky *db2*. Lze si povšimnout potlačení šumu při zachování hran obrazu a patrného rozmazání obrazu. Obr. 42 d) znázorňuje filtrovaný obraz vlnkou *db30*, přičemž si lze povšimnout nepatrně silnějšího rozmazání obrazu.




(a) Obraz znázorňující originální nezašuměný UZ snímek karotid.



(b) Obraz popisující zašuměný snímek břicha Speckle šumem o $d = 2$.



(c) Obraz vyobrazuje filtrovaný obraz pomocí *db2*.




(d) Obraz vyobrazuje filtrovaný obraz pomocí *db30*.

Obrázek 43: Výstup filtrovaného obrazu zašuměného Speckle šumem.


Na obr. 43 lze pozorovat výstup filtrovaného obrazu pomocí vlněk *db2* a *db30*. Obr. 43 a) znázorňuje původní vytvořený UZ snímek z databáze karotidy, obr. 43 b) znázorňuje totožný

obraz uměle zašuměný speckle šumem o hustotě $d = 2$. Obr. 43 c) ukazuje výstup filtrovaného obrazu pomocí vlnky $db2$. Lze si obdobně povšimnout potlačení šumu při zachování hran obrazu a patrného rozmazání obrazu. Obr. 43 d) znázorňuje filtrovaný obraz vlnkou $db30$, přičemž si lze povšimnout lepšího potlačení speckle šumu.



(a) Obraz znázorňující originální nezašuměný UZ snímek krku.

(b) Obraz popisující zašuměný snímek břicha Speckle šumem o $d = 2$.



(c) Obraz vyobrazuje filtrovaný obraz pomocí $db5$.

(d) Obraz vyobrazuje filtrovaný obraz pomocí $db30$.

Obrázek 44: Výstup filtrovaného obrazu zašuměného Speckle šumem.

Obr. 44 vyobrazuje výstup filtrovaného obrazu prostřednictvím vlnek $db5$ a $db30$. Obr. 44 a) znázorňuje originální vytvořený UZ snímek z databáze krk, obr. 44 b) znázorňuje totožný obraz uměle zašuměný speckle šumem o hustotě $d = 2$. Obr. 44 c) ukazuje výstup filtrovaného obrazu pomocí vlnky $db5$. Lze si obdobně povšimnout potlačení šumu, při zachování hran obrazu a patrného rozmazání obrazu. Obr. 44 d) znázorňuje filtrovaný obraz vlnkou $db30$, přičemž si lze povšimnout patrnějšího rozmazání obrazu.

6 Objektivní zhodnocení filtrace Speckle šumu

V této kapitole bude zkoumán vliv nastavení úrovně rozkladu na efektivitu filtrace Speckle šumu pomocí rodiny vlněk *Daubechies* a *Symlets*. V kap. 5 byly shrnuty výsledky testování efektivitu filtrace vlnkovou transformací pomocí vlněk rodiny *Daubechies* o úrovní rozkladu 3. Tato kapitola bude zaměřena na objektivní evaluaci efektivitu kooperativních vlněk při vyšším stupni rozkladu. Testování efektivitu filtrace je provedeno na všech vytvořených reálných datech.

6.1 Výsledky databáze břicho

Dle tab. 10 a tab. 11 jak bylo očekáváno, vlnky typu *db2* a *sym2* vykazují stejnou filtrační účinnost. Důvodem je podobný tvar mateřské vlnky ψ viz 4.4. Lze si povšimnout, že se zvyšující se úrovní rozkladu, klesá efektivita filtrace kooperativních vlněk. Jak je znázorněno v tab. 10 a tab. 11 vlnky rodiny *Symlets* vykazují lepší filtrační účinnost pro Speckle šum. Na obr. 45 lze sledovat závislost efektivitu filtrace kooperativních vlněk pomocí objektivního parametru Q-indexu.


Na obr. 45 a) je znázorněna efektivita filtrace vlněk rodiny *Daubechies* o rozkladu 3 v závislosti na úrovni šumu. Obr. 45 b) znázorňuje efektivitu *Symlets* vlněk při stejném nastavení. Lze vidět, že vlnky rodiny *Symlets* vykazují větší efektivitu při variatní hustotě šumu.

Podle obr. 45 c) lze usuzovat, že se zvyšující se úrovní rozkladu klesá efektivita filtrace vlněk rodiny *Daubechies*. Tentýž trend lze přisuzovat i u vlněk rodiny *Symlets* viz obr. 45 d).


V testované databázi břicho, se nejlépe jeví nastavení úrovně rozkladu 3 a užití vlněk rodiny *Symlets*.

Tabulka 10: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk *Daubechies* pro UZ snímky databáze břicho.


	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>db2</i>	0.9226	0.9095	0.8923	0.8872	0.8555	0.8349
<i>db5</i>	0.8948	0.8708	0.8428	0.8400	0.8255	0.7987
<i>db10</i>	0.8560	0.8343	0.8216	0.8045	0.7852	0.7574
<i>db15</i>	0.8367	0.8203	0.7951	0.7814	0.7656	0.7426
<i>db20</i>	0.8134	0.8081	0.7636	0.7680	0.7321	0.7147
<i>db22</i>	0.8137	0.7856	0.7615	0.7537	0.7306	0.7053
<i>db25</i>	0.8191	0.7786	0.7497	0.7434	0.7224	0.7046
<i>db30</i>	0.7768	0.7721	0.7302	0.7311	0.7377	0.6825




(a) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 3 pomocí parametru Q-index.



(b) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 3 pomocí parametru Q-index.



(c) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 4 pomocí parametru Q-index.



(d) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 4 pomocí parametru Q-index.

Obrázek 45: Porovnání efektivitu filtrace Speckle šumu pomocí vlněk rodiny Daubechies a Symlets o rozdílných úrovni rozkladu pro snímky z databáze břicho.

Tabulka 11: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlnek Symlets pro UZ snímky databáze břicho.

	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>sym2</i>	0.9226	0.9095	0.8923	0.8872	0.8555	0.8349
<i>sym3</i>	0.8959	0.8738	0.8568	0.8584	0.8360	0.8342
<i>sym5</i>	0.8990	0.8864	0.8524	0.8696	0.8409	0.8244
<i>sym10</i>	0.8975	0.8805	0.8462	0.8377	0.8146	0.8296
<i>sym15</i>	0.8616	0.8376	0.8063	0.8122	0.7921	0.7645
<i>sym20</i>	0.8555	0.8305	0.8341	0.8053	0.7851	0.7673
<i>sym25</i>	0.8411	0.8280	0.7920	0.8090	0.7820	0.7542
<i>sym29</i>	0.8422	0.8278	0.8054	0.8023	0.7680	0.7461

6.2 Výsledky databáze karotidy

V testované databázi karotidy lze usoudit, že při nižších úrovni šumu se jeví nejlépe vlnky rodiny *Daubechies*. Lze pozorovat obdobný trend, při vyšší úrovni rozkladu, klesá efektivita filtrace. Dle tab. 12 a tab. 13 lze usoudit, že výběr typu vlnky je závislý na nastavení úrovni šumu. U vlnky *db5* efektivita filtrace při nastavení vyšší úrovně rozkladu klesá z 0.8045 na 0.7515. Tento pokles lze pozorovat u ostatních kooperativních vlněk viz tab. 12, pro *Daubechies* a tab. 13 pro *Symlets*.



Na obr. 46 a) je znázorněna efektivita filtrace vlněk rodiny *Daubechies* o rozkladu 3 v závislosti na úrovni šumu. Obr. 46 b) vyobrazuje efektivitu *Symlets* vlněk při stejném nastavení. Lze si povšimnout, že vlnky rodiny *Symlets* vykazují větší efektivitu při vyšší hustotě šumu.

Podle obr. 46 c) lze vidět, že se zvyšující se úrovni rozkladu klesá efektivita filtrace vlněk rodiny *Daubechies*. Tentýž trend lze přisuzovat i u vlněk rodiny *Symlets* viz obr. 46 d).



V testované databázi karotidy, se nejlépe jeví nastavení úrovně rozkladu 3 a užití vlněk rodiny *Symlets* při vyšší úrovni šumu.

Tabulka 12: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlněk Daubechies pro UZ snímky databáze karotidy.

	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>db2</i>	0.7847	0.7654	0.7648	0.7541	0.7354	0.7267
<i>db5</i>	0.8045	0.7842	0.7355	0.7515	0.7204	0.7088
<i>db10</i>	0.7908	0.7539	0.7243	0.7377	0.7128	0.6821
<i>db15</i>	0.7884	0.7365	0.6929	0.7395	0.7149	0.6776
<i>db20</i>	0.7889	0.7617	0.7148	0.7732	0.6816	0.6803
<i>db22</i>	0.7671	0.7402	0.7277	0.7430	0.6951	0.6741
<i>db25</i>	0.7698	0.7527	0.7196	0.7369	0.6969	0.6953
<i>db30</i>	0.7600	0.7217	0.6876	0.7099	0.6994	0.6691



(a) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 3 pomocí parametru Q-index. (b) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 3 pomocí parametru Q-index.



(c) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 4 pomocí parametru Q-index. (d) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 4 pomocí parametru Q-index.

Obrázek 46: Porovnání efektivitu filtrace Speckle šumu pomocí vlněk rodiny Daubechies a Symlets o rozdílných úrovni rozkladu pro snímky z databáze karotidy.

Tabulka 13: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlnek Symlets pro UZ snímky databáze karotidy.

	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>sym2</i>	0.7847	0.7654	0.7648	0.7541	0.7354	0.7267
<i>sym3</i>	0.7748	0.7539	0.7448	0.7607	0.7441	0.6998
<i>sym5</i>	0.7859	0.7914	0.7641	0.7688	0.7481	0.7065
<i>sym10</i>	0.7885	0.7865	0.7274	0.7504	0.7090	0.6921
<i>sym15</i>	0.7774	0.7370	0.7388	0.7781	0.7102	0.7000
<i>sym20</i>	0.7839	0.7590	0.7283	0.7525	0.7391	0.7070
<i>sym25</i>	0.7766	0.7459	0.7114	0.7505	0.7317	0.7016
<i>sym29</i>	0.7761	0.7690	0.7065	0.7477	0.7074	0.6521

6.3 Výsledky databáze krk



Poslední testovanou databází je krk. Dle tab. 14 a tab. 15 lze porovnat typy vlnek v závislosti na nastavené úrovni šumu. Z výsledku je patrné, že nejlépe se jeví vlnky rodiny *Symlets*. *Daubechies* vlnky prokazují lepší efektivitu filtrace při vyšší úrovni nastaveného rozkladu u více zašuměných dat viz 6. až 7. sloupec tab. 14. To lze pozorovat u vlnky *db10*, která při úrovni šumu ($d = 2$) při úrovni rozkladu 3 dosahuje efektivit 0.8771 a při rozkladu 4 0.8930.

Na obr. 47 a) je znázorněna efektivita filtrace vlnek rodiny *Daubechies* o rozkladu 3 v závislosti na úrovni šumu. Obr. 47 b) vyobrazuje efektivitu *Symlets* vlnek při stejném nastavení. Lze si povšimnout, že vlnky rodiny *Symlets* vykazují lepší efektivitu při vyšší hustotě šumu.

Podle obr. 47 c) lze vidět, že se zvyšující se úrovni rozkladu stoupá efektivita filtrace vlnek rodiny *Daubechies* u vyšších úrovni šumu. Ovšem tento trend nelze přisuzovat i u vlnek rodiny *Symlets* viz obr. 47 d).



Tabulka 14: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlnek Daubechies pro UZ snímky databáze krk.

	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>db2</i>	0.9292	0.9126	0.8877	0.9127	0.9145	0.8849
<i>db5</i>	0.9141	0.9070	0.8795	0.9219	0.8931	0.8670
<i>db10</i>	0.9131	0.8950	0.8771	0.9200	0.8884	0.8930
<i>db15</i>	0.8948	0.8906	0.8678	0.8988	0.8777	0.8548
<i>db20</i>	0.9001	0.8816	0.8663	0.9021	0.8727	0.8517
<i>db22</i>	0.8963	0.8798	0.8520	0.9049	0.8731	0.8463
<i>db25</i>	0.8954	0.8774	0.8589	0.8936	0.8734	0.8524
<i>db30</i>	0.9053	0.8803	0.8521	0.8928	0.8629	0.8421



(a) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 3 pomocí parametru Q-index.

(b) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 3 pomocí parametru Q-index.



(c) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Daubechies o úrovni rozkladu 4 pomocí parametru Q-index.

(d) Graf popisující efektivitu filtrace kooperativních vlněk rodiny Symlets o úrovni rozkladu 4 pomocí parametru Q-index.

Obrázek 47: Porovnání efektivitu filtrace Speckle šumu pomocí vlněk rodiny Daubechies a Symlets o rozdílných úrovni rozkladu pro snímky z databáze krk.

Tabulka 15: Číselné charakteristiky objektivního parametru hodnotící kvalitu obrazové filtrace Speckle šumu pomocí vlnek Symlets pro UZ snímky databáze krk.

	Q-index(-), rozklad 3			Q-index(-), rozklad 4		
	$d = 0.1$	$d = 1$	$d = 2$	$d = 0.1$	$d = 1$	$d = 2$
<i>sym2</i>	0.9292	0.9126	0.8877	0.9127	0.9145	0.8849
<i>sym3</i>	0.9251	0.9125	0.8710	0.9063	0.8937	0.8627
<i>sym5</i>	0.9206	0.9256	0.8902	0.9044	0.8924	0.8621
<i>sym10</i>	0.9286	0.8915	0.8585	0.9094	0.8768	0.8661
<i>sym15</i>	0.9178	0.9077	0.8623	0.8977	0.9083	0.8604
<i>sym20</i>	0.9000	0.8874	0.8588	0.9112	0.8889	0.8556
<i>sym25</i>	0.9119	0.8859	0.8706	0.9117	0.8766	0.8616
<i>sym29</i>	0.9070	0.8856	0.8731	0.8902	0.8566	0.8526

6.4 Výpočetní náročnost algoritmu

Níže uvedené tabulky znázorňují výpočetní náročnost filtrace pro jednotlivé typy šumu. Tabulka uvádí časovou náročnost pro všechna testovaná data. Z tab. viz 16, 17 a 18 je zřejmé, že nejrychlejší filtraci poskytují vlnky rodiny *Daubechies*. Časová náročnost je také zvýšena, jelikož dochází k filtraci i vně věžře ultrazvukových dat. Dochází tak k filtrování černého okolí.

Tabulka 16: Tabulka znázorňující časovou náročnost algoritmu filtrace pro Gaussův šum.

	Daubechies		Symlets	
	Rozklad 3	Rozklad 4	Rozklad 3	Rozklad 4
Břicho	23min	24min	77min	85min
Krk	21min	25min	80min	88min
Karotidy	17min	19min	77min	66min

Tabulka 17: Tabulka znázorňující časovou náročnost algoritmu filtrace pro Salt and Pepper šum.


	Daubechies		Symlets	
	Rozklad 3	Rozklad 4	Rozklad 3	Rozklad 4
Břicho	21min	27min	80min	82min
Krk	19min	26min	88min	82min
Karotidy	18min	16min	74min	77min

Tabulka 18: Tabulka znázorňující časovou náročnost algoritmu filtrace pro Speckle šum.


	Daubechies		Symlets	
	Rozklad 3	Rozklad 4	Rozklad 3	Rozklad 4
Břicho	19min	24min	75min	84min
Krk	26min	25min	71min	84min
Karotidy	16min	20min	76min	81min

6.5 Subjektivní posouzení kvality obrazové filtrace


Subjektivní hodnocení vzniklo ve spolupráci s lékařem radiologem na klinickém pracovišti. Na obr. 48 lze vidět vybraný původní snímek 48 a), který je následně zašuměný 48 b) a poté filtrovaný 48 c). Ultrazvukový snímek je vybrán z databáze břicho. Barevné ukazatele znázorňují anatomické oblasti, které jsou centrem zájmu tohoto vytvořeného snímku. Černá šipka značí větev vrátnicové žíly (vena portae), bílá šipka a zelená poukazují na větve žlučovodu a jaterní tepny (arteria hepatica). Modrá šipka ukazuje na dolní dutou žílu a oranžová popisuje Arantiův vaz (ligamentum venosum). Na obr. 49 jsou výše popsane oblasti zájmu přiblíženy pro přehlednější zobrazení. Lze si povšimnout na obr. 49 b), že zašuměný obraz speckle šumem o úrovni $d = 2$ vede k výraznému zaostření oblastí zájmu, a tak nemožnosti stanovení správné diagnózy. Zejména pro oblasti, které jsou znázorněny černým, zeleným a bílým ukazatelem. Výstup filtrace obrazu je znázorněna na 49 c), kde lze pozorovat potlačení speckle šumu při současném zachování hran. Je možno vidět zlepšení kvality obrazu, a to především v oblastí zájmu znázorněných černým, zeleným a bílým ukazatelem.



(a) Původní ultrazvukový obraz z databáze břicho.




(b) Ultrazvukový obraz z databáze břicho zašuměný o úrovni $d = 2$.




(c) Ultrazvukový obraz z databáze břicho filtrovaný pomocí vlnky db2 a úrovní rozkladu 3.


Obrázek 48: Vybraný ultrazvukový snímek z databáze břicho k subjektivnímu posouzení efektivity filtrace.



(a) Přiblížený původní ultrazvukový obraz z databáze břicho.



(b) Přiblížený ultrazvukový obraz z databáze břicho zašuměný o úrovni $d = 2$.



(c) Přiblížený ultrazvukový obraz z databáze břicho filtrovaný pomocí vlnky $db2$ a úrovně rozkladu 3.

Obrázek 49: Přiblížené oblasti zájmu vybraného ultrazvukového snímku z databáze břicho k subjektivnímu posouzení efektivity filtrace.

7 Diskuze

V této práci byla testována efektivita filtrace pomocí prahování vlnkových koeficientů. K testování byly použity vlnky rodiny *Daubechies* a *Symlets*. K testování efektivita filtrace kooperativních vlnek bylo z rodiny *Daubechies* použito (*db2*, *db5*, *db10*, *db15*, *db20*, *db22*, *db25* a *db30*) a 8 typů z rodiny *Symlets* (*sym2*, *sym3*, *sym5*, *sym10*, *sym15*, *sym20*, *sym25* a *sym29*). Pro testování účinnosti efektivita jednotlivých vlnek se použily skutečné ultrazvukové obrazy. Klinické obrazy byly vytvořeny pomocí přístroje popsaného v kap. 4.1. Přičemž pro testování se použily ultrazvukové snímky z oblasti břicha, krku a karotid. Objektivní hodnocení je poměrně problematické, jelikož neexistuje referenční obraz, který by byl zcela bez šumu. Proto je pro kvantitativní hodnocení přidán šum uměle v prostředí Matlab. Pro testování byly zvoleny tři druhy variantních šumů, Gaussovský, Salt and Pepper a Speckle, který je charakteristický pro ultrazvukové obrazy. Bylo testováno 20 úrovní šumu, kde byla sledována dynamika šumu na efektivitu filtrace pomocí kooperativních typů vlnek. Pro objektivní hodnocení se použily parametry korelace, MSE, SSIM, PSNR a Q-index.

Z výsledku rozsáhlé analýzy je patrné, že výběr ideálního typu vlnky je závislý na typu šumu a úrovni zašumění. Aplikace jednotlivých vlnek je také závislá na typu dat, jak bylo prokázáno v kap. 5. Aplikovaná metoda vzala v úvahu také skutečnost, že při filtrování obrazu se musí dbát na zachování hran, proto je zvolení metody prahování pro účinnost filtrace klíčová. Jelikož šum, který se vyskytuje v ultrazvukových obrazech, může obsahovat důležité diagnostické informace. U Gaussova šumu největší efektivitu vykazovali vlnky rodiny *Daubechies*, konkrétně vlnka *db5* ve všech testovaných databázích. Pro Salt and Pepper šum vlnka *db5* vykazovala horší efektivitu filtrace, a to zejména při vyšších úrovních šumu viz tab. 4. Nejeфекtivněji se při nižších úrovních šumu jevila vlnka *db30*, při rostoucí úrovni vlnka *db20*. Při filtraci Speckle šumu, vlnka *db30* vykazovala nejméně efektivní filtraci v databázi břicho, zatímco vlnka typu *db2* se jevila jako nejúčinnější. Se zvyšující úrovní rozkladu, se snižovala účinnost efektivita filtrace, jelikož docházelo k většímu rozmazání obrazu. To zapříčiní ztrátu detailů obrazu.

Protože výběr správného filtrovacího postupu hraje významnou roli, je důležité experimentovat a porovnat účinnost jednotlivých filtračních metod. Tato práce může být v budoucnu využita jako doporučení pro následné zvolení ideálního typu vlnky a úrovně rozkladu na variantní typy šumu. Filtrace šumu v ultrazvukových obrazech je žádoucí, nejen pro přesnější stanovení diagnózy, ale i pro další kroky zpracování obrazu. Vylepšením práce by mohlo být navržení sofistikovanějšího prahování a následné aplikace, která by se dala využít v klinické praxi. Jako budoucí výzkum by se mohla provést komparace jednotlivých technik filtrace šumu. Předmětem další práce by mohla být segmentace patologických nálezů, či zájmových oblastí.

Závěr

Hlavním cílem diplomové práce bylo vytvoření rešerše a na jejím základě zvolit vhodnou metodu filtrace, která se následně otestovala na reálných klinických ultrazvukových datech. Z rozsáhlé rešerše, sepsané z několika nastudovaných literárních pramenů, byla zvolena vlnková transformace. Tato metoda využívá multirozkladu, kdy rozkládá vstupující signál na aproximační složky (obsahující celkový trend signálu) a detailní složky (poskytující doplňující informace o signálu). Při filtraci vlnkovou transformací se volí vhodný typ vlnky a úroveň rozkladu, proto byla cílem práce studie dynamiky šumu na efektivitu filtrace kooperativních vlněk.

V realizaci byla nejdříve vytvořena testovací databáze. Databáze byla vytvořena pomocí ultrazvukového přístroje GE LOGIQ P6 PRO na klinickém pracovišti. Bylo vytvořeno dohromady 220 ultrazvukových obrazů, které byly rozděleny do třech testovacích databází pojmenovaných podle místa vyšetření. Databáze obsahovaly jak fyziologické UZ obrazy, tak i obrazy s patologickým nálezem. Veškeré snímky byly řádně anonymizovány.

Další část byla věnována implementaci šumových generátorů. Byly zvoleny tři variantní typy šumu - aditivní Gaussovský šum, impulsivní Salt and Pepper a multiplikativní Speckle šum. Speckle šum je typický svým zrnitým charakterem, který se vyskytuje zejména v ultrazvukových obrazech. Zbylé dva šумы byly zvoleny na základě porovnání efektivit filtrace kooperativních vlněk. Bylo nastaveno 20 úrovní šumu o rozdílných hodnotách kvůli zkoumání dynamiky efektivit filtrace s rostoucí úrovní šumu. Vytvořené ultrazvukové obrazy byly uměle zašuměny.

Zašuměná data sloužila k otestování efektivit filtrace kooperativních vlněk pomocí zvolených objektivních parametrů. K testování byly zvoleny vlnky rodiny *Daubechies* a rodiny *Symlets* o úrovni rozkladu 3 a 4. Poté bylo zvolené měkké prahování. Obě rodiny vlněk dosáhly velice uspokojivých výsledků, kdy dokázaly téměř pokaždé odfiltrovat šum při současném zachování hran obrazu. Pro Speckle šum, se nejefektivněji jevila vlnka typu *db2* z UZ databáze břicho, zatímco vlnka *db30* nejhůře. Při testování stejného nastavení v databázi karotidy se jevila vlnka *db30* jako nejefektivnější. Což prokazuje, že zvolení nejefektivnějšího typu vlnky, je mimo jiné závislé na typu zkoumaného snímku.

Následně bylo testování na reálných datech zaměřeno na zkoumání vlivu nastavení úrovně rozkladu. Z výsledků bylo zjištěno, že s rostoucí úrovní rozkladu klesá, účinnost efektivit filtrace. Z dosažených výsledků lze usoudit, že není možno stanovit univerzální typ vlnky na variantní typy šumu. Výběr nejefektivnější vlnky, je také závislý na druhu testovaných obrazů, jak bylo prokázáno v kap. 5. Výsledky testování na reálných ultrazvukových datech byly v mnoha případech uspokojivé pro filtraci šumu z ultrazvukových obrazů.

Literatura

- [1] Christopher L Moore and Joshua A Copel. Point-of-care ultrasonography. *New England Journal of Medicine*, 364(8):749–757, 2011. doi: 10.1056/NEJMra0909487. URL <https://www.nejm.org/doi/full/10.1056/nejmra0909487>.
- [2] R Vanithamani and G Umamaheswari. Speckle reduction in ultrasound images using neighborhood shrink and bilateral filtering. 2014. ISSN 1549-3636. doi: 0.3844/jcssp.2014.623.631. URL <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.685.9754>.
- [3] H Lutz, E Buscarini, and P Mirk. *Manual of Diagnostic Ultrasound Volume 1*. Geneva, CH: World Health Organization Press, 2011. ISBN 978-92-4-154745-1.
- [4] I Hrazdira. *Biofyzikální základy ultrasonografie: Jak pracovat s ultrazvukovým diagnostickým přístrojem*. Olomouc, Univerzita Palackého v Olomouci, 2011. ISBN 978-80-244-2895-6.
- [5] Martin Sedlář et al. *Zobrazovací metody využívající neionizující záření*. Masarykova Univerzita, 2014. ISBN 978-80-210-7156-8. URL <https://portal.med.muni.cz/clanek-616-zobrazovaci-metody-vyuzivajici-neionizujici-zareni.html>.
- [6] Christos P Loizou and Constantinos S Pattichis. *Despeckle filtering algorithms and software for ultrasound imaging*, volume 1. Morgan & Claypool Publishers, 2008. ISBN 9781598296211. URL <https://www.morganclaypool.com/doi/abs/10.2200/S00116ED1V01Y200805ASE001>.
- [7] Robert W Cootney. Ultrasound imaging: principles and applications in rodent research. *Ilar Journal*, 42(3):233–247, 2001. URL <https://doi.org/10.1093/ilar.42.3.233>.
- [8] Haim Azhari. *Basics of biomedical ultrasound for engineers*. John Wiley & Sons, 2010. ISBN 978-0-470-46547-9.
- [9] Jiří Ferda et al. *Základy zobrazovacích metod*. Praha, Galén, 2015. ISBN 978-80-7492-164-3.
- [10] Miroslav Heřman. *Základy radiologie*. Univerzita Palackého, 2014. ISBN 978-80-244-2901-4.
- [11] Peter R Hoskins, Kevin Martin, and Abigail Thrush. *Diagnostic ultrasound: physics and equipment*. Cambridge University Press, 2010. ISBN 978-0-521-75710-2.
- [12] Se Hyung Kim and Byung Ihn Choi. *Three-dimensional and four-dimensional ultrasound: techniques and abdominal applications*, volume 15. Elsevier, 2007. URL [https://doi.org/10.1016/S0929-6441\(08\)60040-5](https://doi.org/10.1016/S0929-6441(08)60040-5).
- [13] Rohit Choudhari and Adwait Aralkar. Denoising medical images using filters. *ASIAN JOURNAL FOR CONVERGENCE IN TECHNOLOGY (AJCT)-UGC LISTED*, 4(II), 2018. ISSN 2350-1146 I.F-5.11. URL <http://www.asianssr.org/index.php/ajct/article/view/549>.

- [14] Miroslav Fribert. *Základy zpracování obrazu*. Univerzita Pardubice, 2013. ISBN 978-80-7395-534-2.
- [15] KS Sim, CP Tso, and YY Tan. Recursive sub-image histogram equalization applied to gray scale images. *Pattern Recognition Letters*, 28(10):1209–1221, 2007. ISSN 0167-8655. doi: <https://doi.org/10.1016/j.patrec.2007.02.003>. URL <https://www.sciencedirect.com/science/article/abs/pii/S0167865507000578>.
- [16] Jan Juráš. *Optimalizace výpočtu konvoluce nad rozsáhlými vícerozměrnými daty*. Bakalářská práce, Masarykova univerzita, Fakulta informatiky. Vedoucí práce RNDr. David Svoboda Ph.D., 2011.
- [17] Tinku Acharya and Ajoy K Ray. *Image processing: principles and applications*. John Wiley & Sons, 2005. ISBN 13-978-0-471-71998-4.
- [18] Palwinder Singh and Leena Jain. *Noise reduction in ultrasound images using wavelet and spatial filtering techniques*. 2013. ISBN 978-81-920249-7-4. URL <https://ieeexplore.ieee.org/abstract/document/6915074>.
- [19] Rohit Verma and Jahid Ali. A comparative study of various types of image noise and efficient noise removal techniques. *International Journal of advanced research in computer science and software engineering*, 3(10), 2013. URL <https://pdfs.semanticscholar.org/6f02/fd9315886f39143e4ae746669e08f53cc507.pdf>.
- [20] Gajanand Gupta. Algorithm for image processing using improved median filter and comparison of mean, median and improved median filter. *International Journal of Soft Computing and Engineering (IJSCE)*, 1(5):304–311, 2011. ISSN 2231-2307.
- [21] Suresh Kumar, Papendra Kumar, Manoj Gupta, and Ashok Kumar Nagawat. Performance comparison of median and wiener filter in image de-noising. *International Journal of Computer Applications (0975–8887) Volume*, 12, 2010. URL <https://pdfs.semanticscholar.org/5b64/ebf95b55ebe4d36c2d5613f4c5983ee2f1a3.pdf>.
- [22] Ashraf Aboshosha, M Hassan, M Ashour, and M El Mashade. *Image denoising based on spatial filters, an analytical study*. 2009. ISBN 978-1-4244-5842-4. URL <https://ieeexplore.ieee.org/document/5384036>.
- [23] Kwame Boateng, Benjamin Weyori, and David Sanka Laar. Improving the effectiveness of the median filter. *International Journal of Electronics and Communication Engineering*, 5:85–97, 01 2012. ISSN 0974-2166. URL https://www.researchgate.net/publication/280925268_Improving_the_Effectiveness_of_the_Median_Filter.
- [24] DRK Brownrigg. The weighted median filter. *Communications of the ACM*, 27(8):807–818, 1984. doi: 10.1145/358198.358222. URL <https://dl.acm.org/citation.cfm?id=358222>.

- [25] Jaakko Astola and Pauli Kuosmanen. *Fundamentals of nonlinear digital filtering*, volume 8. CRC press, 1997. ISBN 0-8493-2570-6.
- [26] Milan Sonka, Vaclav Hlavac, and Roger Boyle. *Image processing, analysis, and machine vision*. Cengage Learning, 2014. ISBN 978-1133593607.
- [27] Abbas Ebrahimi Moghadam, Pedram Mohammadi, and Shahram Shirani. Subjective and objective quality assessment of image: A survey. *Majlesi Journal of Electrical Engineering*, 9, 2015. URL <https://profdoc.um.ac.ir/articles/a/1048833.pdf>.
- [28] Vrástislav Harabiš. *Registrace obrazů - aplikace v oftalmologii a ultrasonografii*. Doktorská práce, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Vedoucí práce doc. Ing. Radim Kolář Ph.D., 2013.
- [29] RSH Istepanian, N Philip, MG Martini, N Amso, and P Shorvon. Subjective and objective quality assessment in wireless teleultrasonography imaging. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pages 5346–5349. IEEE, 2008. doi: 10.1109/IEMBS.2008.4650422. URL <https://ieeexplore.ieee.org/abstract/document/4650422>.
- [30] Christos P Loizou, Constantinos S Pattichis, Marios Pantziaris, T Tyllis, and Andrew Nicolaides. Quality evaluation of ultrasound imaging in the carotid artery based on normalization and speckle reduction filtering. *Medical and Biological Engineering and Computing*, 44(5):414, 2006. doi: <https://doi.org/10.1007/s11517-006-0045-1>. URL <https://link.springer.com/article/10.1007/s11517-006-0045-1>.
- [31] R Vanithamani, G Umamaheswari, and M Ezhilarasi. *Modified hybrid median filter for effective speckle reduction in ultrasound images*. 2010. ISBN 978-960-474-162-5.
- [32] Zhou Wang and Alan C Bovik. A universal image quality index. *IEEE signal processing letters*, 9(3):81–84, 2002. doi: 10.1109/97.995823. URL <https://ieeexplore.ieee.org/abstract/document/995823>.
- [33] M Lane, David Scott, Mikki Hebl, Rudy Guerra, Dan Osherson, and Heidi Zimmer. e-statistics education: A multimedia course of study. *Retrieved from*, 2009. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.650.8291&rep=rep1&type=pdf>.
- [34] Ajay Kumar Boyat and Brijendra Kumar Joshi. A review paper: noise models in digital image processing. *arXiv preprint arXiv:1505.03489*, 2015. doi: 10.5121/sipij.2015.6206. URL <https://arxiv.org/ftp/arxiv/papers/1505/1505.03489.pdf>.
- [35] V Damerjian, O Tankyevych, N Souag, and E Petit. Speckle characterization methods in ultrasound images—a review. *Irbm*, 35(4):202–213, 2014. URL <https://doi.org/10.1016/j.irbm.2014.05.003>.

- [36] Sandeep Kaur and Navdeep Singh. Image denoising techniques: A review. *International Journal of Innovative Research in Computer and Communication Engineering*, 2(6), 2014. ISSN 2320-9801. URL <https://pdfs.semanticscholar.org/0938/04ab7f6a60900721c82a3cea4255d8874930.pdf>.
- [37] Pierrick Coupé, Pierre Hellier, Charles Kervrann, and Christian Barillot. Nonlocal means-based speckle filtering for ultrasound images. *IEEE transactions on image processing*, 18(10):2221–2229, 2009. doi: 10.1109/TIP.2009.2024064. URL <https://ieeexplore.ieee.org/abstract/document/4982678>.
- [38] Jong-Sen Lee. Digital image enhancement and noise filtering by use of local statistics. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (2):165–168, 1980. doi: 10.1109/TPAMI.1980.4766994. URL doi.ieeecomputersociety.org/10.1109/TPAMI.1980.4766994.
- [39] A Stella and B Trivedi. Implementation of some speckle filters on digital image and oct image. *International Journal of Computer Science Engineering and Information Technology Research*, 3(6):267–72, 2013.
- [40] R Sivakumar, MK Gayathri, and D Nedumaran. Speckle filtering of ultrasound b-scan images-a comparative study between spatial and diffusion filters. pages 80–85, 2010. doi: 10.1109/ICOS.2010.5720068. URL <https://ieeexplore.ieee.org/abstract/document/5720068>.
- [41] Victor S Frost, Josephine Abbott Stiles, K Sam Shanmugan, and Julian C Holtzman. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (2):157–166, 1982. ISSN 0162-8828. doi: 10.1109/TPAMI.1982.4767223. URL doi.ieeecomputersociety.org/10.1109/TPAMI.1982.4767223.
- [42] Darwin T Kuan, Alexander A Sawchuk, Timothy C Strand, and Pierre Chavel. Adaptive noise smoothing filter for images with signal-dependent noise. *IEEE transactions on pattern analysis and machine intelligence*, (2):165–177, 1985. ISSN 1939-3539. doi: 10.1109/TPAMI.1985.4767641. URL <https://ieeexplore.ieee.org/abstract/document/4767641>.
- [43] Pietro Perona and Jitendra Malik. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on pattern analysis and machine intelligence*, 12(7):629–639, 1990. ISSN 1939-3539. doi: 10.1109/34.56205. URL <https://ieeexplore.ieee.org/abstract/document/56205>.
- [44] R Sivakumar and D Nedumaran. Comparative study of speckle noise reduction of ultrasound b-scan images in matrix laboratory environment. *International Journal of Computer*

- Applications*, 10(9):46–50, 2010. doi: 10.5120/1506-2024. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.206.5194&rep=rep1&type=pdf>.
- [45] David L Donoho and Jain M Johnstone. Ideal spatial adaptation by wavelet shrinkage. *biometrika*, 81(3):425–455, 1994. doi: 10.1093/biomet/81.3.425. URL <https://academic.oup.com/biomet/article-abstract/81/3/425/256924>.
- [46] Rajesh Kumar Rai, Jyoti Asnani, and TR Sontakke. Review of shrinkage techniques for image denoising. *International Journal of Computer Applications*, 42(19):13–16, 2012. doi: 10.5120/5799-8009. URL <https://pdfs.semanticscholar.org/916a/bbf05323df7a20c733ebff4b741a7051f777.pdf>.
- [47] David L Donoho and Iain M Johnstone. Adapting to unknown smoothness via wavelet shrinkage. *Journal of the american statistical association*, 90(432):1200–1224, 1995. doi: 10.1080/01621459.1995.10476626. URL <https://www.tandfonline.com/doi/ref/10.1080/01621459.1995.10476626?scroll=top>.
- [48] S Grace Chang, Bin Yu, and Martin Vetterli. Adaptive wavelet thresholding for image denoising and compression. *IEEE transactions on image processing*, 9(9):1532–1546, 2000. doi: 10.1109/83.862633. URL <https://ieeexplore.ieee.org/abstract/document/862633>.
- [49] Payal Gupta and Amit Kumar Garg. Image denoising using bayes shrink method based on wavelet transform. *International Journal of Electronic and Electrical Engineering*, 8(1):33–40, 2015. ISSN 0974-2174. URL <https://pdfs.semanticscholar.org/b22e/6cb13a501ffa671037d2923731a4cfb5c601.pdf>.
- [50] K Karthikeyan and C Chandrasekar. Speckle noise reduction of medical ultrasound images using bayesshrink wavelet threshold. *International Journal of computer applications*, 22(9):8–14, 2011. doi: 10.5120/2614-3646. URL <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.206.3725&rep=rep1&type=pdf>.
- [51] GE Medical Systems. *Logiq P6 Pro - TruScan Imaging Technology*. 2010. URL <http://trisonics.com/ckfinder/userfiles/files/LOGIQ-P6-Pro.pdf>.
- [52] Amara Graps. "an introduction to wavelets". *IEEE Comp. Sci. Engi.*, 2:50–61, 02 1995. doi: 10.1109/99.388960.
- [53] Anestis Antoniadis, Jeremie Bigot, and Theofanis Sapatinas. Wavelet estimators in nonparametric regression: a comparative simulation study. *Journal of statistical software*, 6:pp–1, 2001. ISSN 1548-7660. URL <https://www.jstatsoft.org/article/view/v006i06>.
- [54] Radislav Šmíd. Úvod do vlnkové transformace. *ČVUT FEL katedra měření*, 2001. URL <https://docplayer.cz/19249380-Uvod-do-vlnkove-transformace.html>.

- [55] E Anisimova, J Bednář, and P Páta. Zpracování obrazu pomocí vlnkové transformace. *Electro revue*, 2013. ISSN 1213-1539. URL <http://www.elektrorevue.cz/cz/clanky/zpracovani-signalu/10/zpracovani-obrazu-pomoci-vlnkove-transformace--image-processing-\@Musing-the-wavelet-transform-/>.
- [56] Michel Misiti, Yves Misiti, Georges Oppenheim, and Jean-Michel Poggi. Wavelet toolbox. *The MathWorks Inc., Natick, MA*, 15:21, 1996. URL http://feihu.eng.ua.edu/NSF_TUES/w7_1a.pdf.
- [57] Dipalee Gupta and Siddhartha Choubey. Discrete wavelet transform for image processing. *International Journal of Emerging Technology and Advanced Engineering*, 4(3):598–602, 2015. ISSN 2250-2459. URL <https://pdfs.semanticscholar.org/ef76/c68500794b4d4643b3ce62a64b0ab646f888.pdf>.
- [58] Chih-Chin Lai and Cheng-Chih Tsai. Digital image watermarking using discrete wavelet transform and singular value decomposition. *IEEE Transactions on instrumentation and measurement*, 59(11):3060–3063, 2010. doi: 10.1109/TIM.2010.2066770. URL <https://ieeexplore.ieee.org/abstract/document/5560822>.
- [59] A. Benkrid, K. Benkrid, and D. Crookes. Design and implementation of a generic 2d orthogonal discrete wavelet transform on fpga. *IEEE Comp. Sci. Engi.*, pages 162–172, 2003. doi: 10.1109/FPGA.2003.1227252. URL <https://ieeexplore.ieee.org/abstract/document/1227252>.
- [60] David L Donoho. De-noising by soft-thresholding. *IEEE transactions on information theory*, 41(3):613–627, 1995. doi: 10.1109/18.382009. URL <https://ieeexplore.ieee.org/abstract/document/382009>.
- [61] Lucien Birgé and Pascal Massart. From model selection to adaptive estimation. pages 55–87, 1997. doi: 10.1007/978-1-4612-1880-7_4. URL https://link.springer.com/chapter/10.1007/978-1-4612-1880-7_4.

A Seznam příloh na přiloženém DVD

K této práci je přiloženo DVD obsahující reálná klinická data poskytnutá z klinického pracoviště. DVD obsahuje použité algoritmy a funkce.

Obsah DVD

- Složka *Data* obsahuje výsledky testování vybraných databází, které jsou uloženy v *.mat* souborech. Výsledky jednotlivých databází jsou rozděleny do třech podsložek nazvané dle testované databáze. Ve složce *data* je uložen soubor *Data Hlavička.pdf*, který popisuje jednotlivé datové soubory.
- Složka *Kódy a Algoritmy* obsahuje všechny použité zdrojové kódy v *.m* souborech. Součástí této složky je také soubor *Algoritmy Hlavička.pdf*, kde jsou zdrojové soubory popsány.
- součástí DVD je uložená textová část diplomové práce ve formátu PDF/A nazvaná *VIL0070 Diplomová práce.pdf*.